

**KÜTAHYA DÜMLUPINAR ÜNİVERSİTESİ
EĞİTİM BİLİMLERİ ENSTİTÜSÜ
TEMEL EĞİTİM ANABİLİM DALI
SINIF EĞİTİMİ BİLİM DALI**

**İLKÖĞRETİM LGS FEN BİLİMLERİ BAŞARISININ YAPAY
SİNİR AĞLARI İLE TAHMİN EDİLMESİ**

**Ahmet ATASAYAR
Yüksek Lisans Tezi**

**Tez Danışmanı
Doç. Dr. Metin DEMİR**

Kütahya, 2019

Yemin Metni

Yüksek lisans tezi olarak sunduđum “İlköğretim LGS Fen Bilimleri Başarısının Yapay Sinir Ağları ile Tahmin Edilmesi” adlı çalışmamın, tarafımdan bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın yazıldığını ve yararlandığım kaynakların “Kaynaklar” bölümünde gösterilenlerden oluştuđunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve bunu onurumla doğrularım.

14/06/2019

Ahmet ATASAYAR

Kabul ve Onay

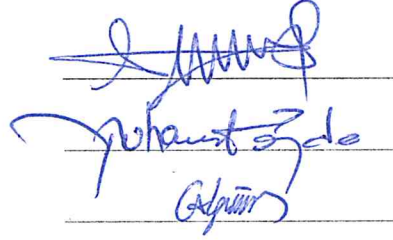
Yazar Ahmet ATASAYAR'ın hazırlamış olduđu "İlköğretim LGS Fen Bilimleri Başarısının Yapay Sinir Ağları İle Tahmin Edilmesi" başlıklı yüksek lisans tez çalışması, jüri tarafından lisansüstü yönetmeliğinin ilgili maddelerine göre değerlendirilip oybirliği ile kabul edilmiştir.

16/07/2019

Doç. Dr. Metin DEMİR (Danışman)

Dr. Öğr. Üyesi Muhammet ÖZDEN

Dr. Öğr. Üyesi Ergün AKGÜN



Doç. Dr. Baykal BİÇER

Eğitim Bilimleri Enstitüsü Müdürü

Önsöz ve Teşekkür

Bilgisayar teknolojilerinin gelişmesiyle birlikte insanoğlu neredeyse tüm işlemlerini bu yenilikçi teknolojiler üzerinde yapmakta ve yeni yöntemlerin bulunmasına olanak sağlamaktadır. İşte bu yüzdendir ki, 1950 yılında ortaya atılan “Makineler düşünebilir mi?” fikri ortaya çıkmıştır. 1990’lı yıllara gelindiğinde ise Yapay Sinir Ağları teknolojisi iyiden iyiye hızlanmış ve büyük bir gelişme görülmüştür. Yapay sinir ağları örneklerle ilgili bilgiler toplamakta, genellemeler yapmakta ve daha sonra hiç görmediği örnekler ile karşılaştırılınca öğrendiği bilgileri kullanarak o örnekler hakkında karar verebilmektedir. Yapay sinir ağlarının tıp, işletme, saf bilimler, veri madenciliği, telekomünikasyon ve işletme yönetimleri gibi alanlarda örüntü tanıma ve tahmin etme uygulamaları bulunmaktadır.

Bu çalışmada, öğrencilerin LGS (Liselere Geçiş Sınavı) Fen Bilimleri dersi alt testinde yaptıkları doğru ve yanlış sayılarını yordadığı düşünülen; ilkokul 4. Sınıf ve ortaokul 5., 6., 7. ve 8. sınıf Fen Bilimleri dersi sınav notları birer yordayıcı değişken olarak ele alınmıştır. Bu değişkenlerin, LGS Fen Bilimleri Dersi başarısını ne derece yordadığının belirlenmesinde ise yapay sinir ağları kullanılmıştır.

Bu çalışmanın her aşamasında bilgi ve tecrübelerini benimle paylaşan ve verdiği fikirlerle tezimi şekillendiren, her konuda çok şey öğrendiğim danışman hocam Doç. Dr. Metin DEMİR’e en içten saygı ve sonsuz şükranlarımı sunarım.

Yapay sinir ağları ile ilgili öğrenme yolculuğumda yardımlarını esirgemeyen Dr. Öğr. Üyesi Ergün AKGÜN ve Emrah HASPOLAT’a, tezimi yazmam konusunda beni cesaretlendiren Özkan ÖZGÜMÜŞ’e teşekkür ederim.

Bugünlerimin hazırlayıcıları sevgili anne ve babama, tezi yazmam aşamasında bana destek olan, sabır, anlayış ve fedakârlık gösteren hayat arkadaşım, değerli eşim Fatma ATASAYAR’ a ve canım evlatlarım Zümra ve Serra’ya sonsuz teşekkürlerimi sunarım.

İçindekiler

İçindekiler

Yemin Metni	i
Kabul ve Onay.....	ii
Önsöz ve Teşekkür	iii
İçindekiler	iv
Tablolar Dizini	vi
Şekiller Dizini	vii
Simgeler ve Kısaltmalar	viii
Özet	ix
Abstract	x
Birinci Bölüm.....	1
Giriş.....	1
Kuramsal/Kavramsal Çerçeve	1
Fen Bilimleri Dersi Öğretim Programlarının Yapısı ve Değişimi	1
Akademik Başarının Yordanması	5
Orta Öğretime Geçiş Sistemi	8
Yapay Sinir Ağları	10
Yapay Sinir Ağlarının Tanımı	10
Yapay Sinir Ağlarının Tarihçesi	11
Biyolojik Sinir Hücreleri ve Yapay Sinir Ağları	12
Yapay Sinir Ağlarının Yapısı ve Temel Bileşenleri	15
Yapay Sinir Ağlarının Genel Özellikleri	20
Yapay Sinir Ağlarının Sınıflandırılması	22
Yapay Sinir Ağlarının Kullanım Alanları.....	25

Araştırmanın Tanımları.....	26
Problem Durumu.....	27
Araştırmanın Amacı.....	31
Araştırmanın Önemi.....	31
Problem Cümlesi.....	32
Varsayımlar (Sayılıtlar)	32
Araştırmanın Sınırlılıkları.....	32
İlgili Çalışmalar	33
İkinci Bölüm.....	39
Yöntem.....	39
Araştırmanın Modeli.....	39
Çalışma Grubu	39
Verilerin Toplanması	39
Verilerin Düzenlenmesi	40
Verilerin Analizi	42
Üçüncü Bölüm	51
Bulgular.....	51
Birinci Alt Probleme İlişkin Bulgular.....	51
İkinci Alt Probleme İlişkin Bulgular.....	53
Dördüncü Bölüm.....	64
Sonuç Tartışma ve Öneriler	64
Sonuç.....	64
Tartışma	65
Öneriler	67
Kaynaklar	69
Ekler	79
Özgeçmiş.....	80

Tablolar Dizini

Tablo 1. Biyolojik Sinir Ağı ve YSA' nın Karşılaştırılması.....	15
Tablo 2. Toplama Fonksiyonu Örnekleri.....	18
Tablo 3. Bazı Aktivasyon Fonksiyonu Örnekleri.....	19
Tablo 4. Çalışma Alanının Temizlenmesi ve Veri Setinin Yüklenmesini Gösteren Kodlar.....	44
Tablo 5. Ağ Yapısı ve Özelliklerinin Belirlendiği Kodlar.....	46
Tablo 6. Ağın Öğrenme Parametrelerinin Belirlendiği Kodlar.....	46
Tablo 7. Ağın Eğitim Aşamasının Tanımlandığı Kodlar.....	47
Tablo 8. Ağın Simüle Edilerek Tahmin Performansının Belirlendiği Kodlar.....	48
Tablo 9. Ağın Sonuç Grafiklerinin ve Tablosunun Oluşturulduğu Kodlar.....	48
Tablo 10. Fen Bilimleri Yazılı Sınav ve LGS Fen Bilimleri Alt Test Doğru Sayılarına İlişkin Aritmetik Ortalama ve Standart Sapma.....	52
Tablo 11. Fen Bilimleri Yazılı Sınav ve LGS Fen Bilimleri Alt Test Doğru Sayıları Arasındaki Korelasyonlar.....	53
Tablo 12. Oluşturulan Ağ Mimarisinin Özelliklerini Gösteren Çizelge.....	53
Tablo 13. Oluşturulan Yapay Sinir Ağı Modelinin Çalıştırılması ile Elde Edilen Birinci Deneme Sonuçları.....	54
Tablo 14. On Denemede Elde Edilen En İyi Performansları Gösteren Çizelge....	59

Şekiller Dizini

Şekil 1. 2005 Fen ve teknoloji dersi öğretim programı kazanımlar ilişkisi (MEB,2005b).....	3
Şekil 2. Biyolojik sinir hücresinin yapısı.....	13
Şekil 3. Sinir sisteminde bilgi akışı.....	13
Şekil 4. Biyolojik ve yapay sinir ağlarının benzerliği.....	14
Şekil 5. Yapay sinir ağının genel yapısı.....	15
Şekil 6. Yapay nöronun genel yapısı.....	16
Şekil 7. Yapay sinir ağlarının ağ yapıları.....	22
Şekil 8. İleri beslemeli yapay sinir ağlarının yapısı.....	24
Şekil 9. Geri beslemeli yapay sinir ağlarının yapısı.....	24
Şekil 10. LGS' ye giren öğrencilerin düzenlenen sınav sonuç bilgileri.....	40
Şekil 11. Excel programında yazılan makronun ekran görüntüsü.....	41
Şekil 12. Öğrencilerin Fen Bilimleri dersine ait yazılı sınav puan bilgileri.....	41
Şekil 13. Ağın oluşturulması için yapılan veri seti işlemleri.....	43
Şekil 14. 29 girdi değişkenli, bir gizli katmanlı, 20 gizli hücre sayılı örnek ileri kademeli geri yayılım ağ mimarisi.....	49
Şekil 15. Öğrenme, doğrulama ve test süreçlerine ilişkin regresyon grafikleri.....	60
Şekil 16. Tahmin veri seti kullanılarak ağın tahmin ettiği başarı notları ile kişilerin gerçek başarı notlarının grafiksel karşılaştırılması.....	62
Şekil 17. Tahmin edilen ağın hata değerlerinin dağılımı.....	63

Simgeler ve Kısaltmalar

ÇKA	: Çok Katmanlı Algılayıcı
LGS	: Liselere Geçiş Sınavı
LR	: Lojistik Regesyon
MATLAB	: Matrix Laboratory
MSE	: Ortalama Hata Kareleri
PISA	: Uluslararası Öğrenci Değerlendirme Programı
RMSE	: Karekök Ortalama Hata Kareleri
TIMSS	: Uluslararası Matematik ve Fen Eğilimleri Araştırması
YSA	: Yapay Sinir Ağları



Özet

İlköğretim LGS Fen Bilimleri Başarısının Yapay Sinir Ağları ile Tahmin Edilmesi

Bu çalışmada, ilkokul 4. sınıftan itibaren öğrencilerin Fen Bilimleri derslerindeki başarılarının, bir üst sınıf seviyesindeki başarılarıyla da ilişkilendirmek suretiyle liselere giriş sınavındaki Fen Bilimleri başarısını yapay sinir ağları ile ne düzeyde yordadığını araştırmak amaçlanmıştır. Bu amaç doğrultusunda 4., 5., 6., 7. ve 8. sınıf düzeyinde öğrencilerin Fen Bilimleri akademik başarıları ile LGS Fen Bilimleri Alt Testi başarılarının ilişkisini incelemek üzere SPSS programında Pearson Moment Çarpım Korelasyonu analiz sonuçlarına; ne düzeyde yordadığına ise MATLAB programında yapay sinir ağıyla modelleme performanslarına bakılmıştır. Araştırmada kullanılan veri setleri, Bursa ilinin 17 ilçesindeki 24 okuldan 2017-2018 eğitim-öğretim yılında mezun olmuş aynı zamanda 2018 LGS' ye giren 1027 öğrencinin, 4. sınıftan 8. sınıfa kadar olan geçmiş döneme ait not fişleri ve kişisel bilgi içermeyen LGS sonuç belgeleri MEB E-okul sisteminden elde edilmiştir. Araştırma kapsamında LGS Fen Bilimleri Alt Testi ile Fen Bilimleri sınav başarısı arasındaki korelasyonlar incelendiğinde ($p < 0.001$) en yüksek korelasyonun 8. Sınıf fen bilimleri sınavları arasında ($r = 0.70$) olduğu, en düşük korelasyonun LGS Fen Bilimleri Alt Testi ile 4. Sınıf Fen Bilimleri sınav başarısı arasında ($r = 0.57$) olduğu görülmüştür. Bu sonuca göre; Fen Bilimleri Dersi Öğretim Programının, 4. sınıftan 8.sınıfa kadar sarmal ve bütüncül yapıda olmasıyla sınıflar arasında elde edilen orta ve yüksek düzey ilişkinin alakalı olduğu söylenebilir. İkinci alt problem kapsamında oluşturulan ağ mimarisinde 845 öğrenci verisi ile eğitilen ağda Öğrenme $R = 0.8059$, Doğrulama $R = 0.7408$, Test $R = 0.7568$, RMSE= 2.3504 değerleri en yüksek performans olarak bulunmuştur. 182 öğrencinin verileri kullanılarak ağın eğitim sürecinden sonra simüle edilen gerçek LGS Fen Bilimleri Alt Testi doğru sayıları ile bilgisayarın tahmin ettiği doğru sayıları karşılaştırıldığında $r = 0.7506$ ($p < 0.001$) ile yüksek düzey ilişki olduğu saptanmıştır. Ayrıca, 20 sorudaki ağın tahmin performansına bakıldığında, 182 öğrencide 124 öğrencinin [+2,-2] hata değeri aralığında doğru tahmin edildiği sonucuna ulaşılmıştır.

Anahtar Kelimeler: Fen bilimleri, liselere geçiş sınavı, sınıf eğitimi, yapay sinir ağları.

Abstract

The Prediction of Science Success at High School Entrance Exam with Artificial Neural Network

In this study, it is aimed to investigate the level of predicting the success of Science in high school entrance exam (LGS) by using artificial neural networks (YSA) by associating the success of students in Science classes from 4th grade elementary school to the higher-class level. For this purpose, Pearson Moment Product Correlation analysis results were analysed in SPSS program in order to examine the relationship between the academic achievement of Science Grade and LGS Science Sub-Test achievement of 4th, 5th, 6th, 7th and 8th grade students. In MATLAB program, artificial neural network modelling performance was examined to understand the level of predicting. Data sets used in the research were obtained from the Ministry of Education E-school system for 1027 students who graduated from 24 schools in 17 districts of Bursa in the 2017-2018 academic year and also entered 2018 LGS, and their marks from the 4th to 8th grade and LGS result documents that do not contain personal information. In the scope of research, when the correlations between the LGS Science Sub-Test and Science test success were examined ($p < 0.001$), the highest and lowest correlations were found the 8th grade science exams ($r = 0.70$) and the 4th grade science exams ($r = 0.57$), respectively. According to this result, it can be said that the medium and high-level relationship between the classes is related with the fact that the science course curriculum is spiral and holistic structure from 4th grade to 8th grade. The highest performance values were found as Learning R = 0.8059, Verification R = 0.7408, Test R = 0.7568, RMSE = 2.3504 at the network architecture which was generated in the second sub-problem and the trained network with 845 student data. Using the data of 182 students, it was obtained a high-level relationship with $r=0.7506$ ($p<0.001$), while the correct numbers of simulated real LGS Science Sub-Test compared with the correct numbers predicted by the computer after the training process of the network. In addition, considering the predictive performance of the network in 20 questions, it was obtained that 124 students in 182 students were correctly estimated in [+ 2, -2] error value range.

Keywords: Science, High School Entrance Exam, Classroom Training, Artificial Neural Network.

Birinci Bölüm

Giriş

Bu bölümde araştırmanın kuramsal/kavramsal çerçevesine, problem durumuna, amacına, önemine, problem cümlesine, araştırmaya ilişkin varsayımlara, sınırlılıklara, tanımlara ve kısaltmalara yer verilmiştir.

Kuramsal/Kavramsal Çerçeve

Fen Bilimleri Dersi Öğretim Programlarının Yapısı ve Değişimi

Fen bilimleri, durağan ve mutlak bilgi bütünü değildir (MEB, 2006). Fen bilimleri dünyayı tanımaya ve tanımlamaya çalıştığı gibi doğada gerçekleşen olayları çözümlenmeye, altlarında yatan sebepleri görmeye, açıklamaya ve gelecek hadiseleri önceden tahmin ederek gerekli tedbirlerin alınabilmesi için neler yapılabileceğini söylemeye çalışır. Tabii hadiselerin sonuçlarına, varlığı deneyle kanıtlanmış durumlarına yine hadiselerin olmasına veya belli bir hâlde bulunmasına yol açan sebep-sonuç ilişkisine bakarak tahminde bulunmaya çalışır. Fen bilimlerindeki bu tarz çalışmalar ve çıkarımlar ancak üst düzey zihinsel beceriler ile yapılabilir. Bunlar ise fen bilimleri dersinin öğrencilere sağladığı becerilerdir (Gürdal, 1997). Millî Eğitim bakanlığı, Fen Bilimleri Dersi Öğretim Programının vizyonunu; “Tüm öğrencileri fen okuryazarı bireyler olarak yetiştirmek” olarak tanımlanmıştır. Kazanım olarak ta etkili karar veren, araştırma yapan, sorabilen, sorunları çözümlenebilen, beraber çalışabilen, iletişimi kuvvetli, öz benliğini bilen kendine itimat eden, hayat boyu fen okuryazarı kişiler hedeflenmiştir (MEB, 2013).


Cumhuriyet döneminde hem ilkokul 4 ve 5. sınıflar hem de ortaokul 6, 7 ve 8. Sınıflar ilk kez 1992 öğretim programında birlikte ele alınmıştır. Bunun yanı sıra 2013 ve 2017 öğretim programlarında ise 3, 4, 5, 6, 7 ve 8. sınıflar bütüncül olarak ele alınmıştır. İlköğretim 1992 fen öğretim programında fen konuları 4. sınıftan 8. sınıfa kadar parçalanmayarak, tam olarak ele alınmış ve Fen Bilgisi adı altında okutulmuştur. Bütün sınıf seviyeleri için haftada 4 ders saati şeklinde planlanmıştır (MEB, 1992). Fen Bilgisi dersinde hem ilkokul 4 ve 5 hem de ortaokul 6, 7 ve 8. sınıflar için ortak olarak 22 adet genel amaç belirlenmiştir. Aynı zamanda sınıf

seviyesindeki ünitelerin altında verilen amaçlarla genel amaçlara ulaşılmaya çalışılmıştır. İlkokulda genel amaca ulaşmak için 4. Sınıfın ünitelerinde 42, 5. sınıf sınıfın ünitelerinde ise 38 adet amaç yazılmıştır. Ortaokulda ise 6. sınıfta 25, 7. sınıfta 28 ve 8. sınıfta 39 amaç belirlenmiştir (MEB, 1995, s. 291-325).

İlköğretim 2000 fen öğretim programında fen konuları 4. sınıftan 8. sınıfa kadar ilköğretim olarak ele alınmış olup Fen Bilgisi dersi adı altında haftada 4 ders saati şeklinde okutulmuştur (MEB, 2000). Bu öğretim programının amacı yakın ve uzak çevreleriyle etkileşim halinde gözlem ve deneysel yolla veri toplayıp bunları analiz eden, sunan ve paylaşan fen ile ilgili okur-yazar bireyler yetiştirmektir (MEB, 2000, s. 1004). Belirlenen hedefe ulaşmak için öğrenci merkezli anlayış benimsenip yapıcı-yaratıcı yöntemlere göre hazırlanmıştır. Bununla birlikte bu öğretim programında çağdaş öğretim programlarında olan vizyon ifadesine de yer verilmiştir. Fen Bilgisi dersinin amacı hem ilkokul 4 ve 5 hem de ortaokul 6, 7 ve 8. sınıflar için ortak olarak 10 adet genel amaç belirlenmiş olup sınıf seviyesindeki ünitelerin altında verilen kazanımlarla bu amaçlara ulaşılmaya çalışılmıştır. İlkokulda genel amaca ulaşmak için 4. sınıfın ünitelerinde 97, 5. sınıfın ünitelerinde ise 106 adet kazanım yazılmıştır. Ortaokulda ise genel amaca ulaşmak için 6. sınıfta 147, 7. Sınıfta 104 ve 8. sınıfta 122 kazanım belirlenmiştir (MEB, 2000).

İlköğretim 2005 fen öğretim programında yapılandırıcı öğrenme yaklaşımı esas alınarak öğretim programında öğrenciyi etkin kılan öğretim stratejilerine ağırlık vermiştir. Öğretim programında konuların 4. sınıftan 8. sınıfa kadar parçalanmayarak, bütüncül olarak ele alındığı görülmektedir. Ayrıca bütün sınıf seviyelerinde konuların işlenme süresi haftada 4'er ders saati olarak okutulması öngörülmüştür (MEB, 2005b; MEB, 2006).

2005 öğretim programının içerik yapısı, birbiri ile ilişkili olan Şekil 1'de belirtilen 7 öğrenme alanından oluşturulmuştur.



Şekil 1. 2005 Fen ve teknoloji dersi öğretim programı kazanımlar ilişkisi (MEB, 2005b).

Bu öğrenme alanlarından 4'ü (Fiziksel Olay, Madde ve Değişim, Canlılar ve Hayat, Dünya ve Evren) ile öğrencilere kazandırılması planlanan fen bilimine ilişkin temel kavram bilgileri bu alanlardan seçilen ünitelerle verilmektedir. Diğer üç öğrenme alanıyla da (Bilimsel Süreç Becerileri (BSB), Fen-Teknoloji-Toplum-Çevre (FTTÇ), Tutum ve Değer (TD)) öğrencilerin fen ve teknoloji okuryazarlığı için gerekli olan fen bilimine ilişkin anlayış ve beceriyi kazandıracak etkinliklere yer verilmektedir (MEB, 2005b; MEB, 2006).

İlköğretim 2013 fen öğretim programında ise içerik 3. sınıftan 8. sınıfa kadar bütüncül olarak ele alınıp Fen Bilimleri dersi adı altında okutulmuştur (MEB, 2013). Mecburi eğitim süresinin 12 yıl yapılması ile ilkokul 1. 2. 3. ve 4. sınıf, ortaokul ise 5, 6, 7 ve 8. sınıf olarak kabul edilmiştir. Bununla beraber ilk defa fen içerikli konular ilkokul 3. sınıfta Fen Bilimleri dersi olarak uygulanmaya başlanmıştır. Öğretim programında yer alan konuların işlenme süresi ilkokul 3. ve 4. sınıflarda haftada 3 saat, ortaokul 5., 6., 7. ve 8. sınıf düzeyinde ise 4 saat ile sınırlandırılmıştır. 2013 Fen Bilimleri dersi öğretim programının vizyonu, bütün öğrencilerin fen okuryazarı olarak yetiştirilmesi şeklindedir (MEB, 2013). Bu vizyona ulaşmak için Fen Bilimleri dersi öğretim programında bütün sınıf seviyelerini kapsayan 12 adet temel amaç belirlenmiştir. Öğretim programının uygulanmasında, 3. ve 4. sınıf düzeyinde yapılandırılmış araştırma sorgulama, 5.

ve 6. sınıf düzeyinde rehberli araştırma-sorgulama ve 7. ve 8. sınıf düzeyinde ise açık uçlu araştırma sorgulama benimsenmiştir (MEB, 2013).

Fen Bilimleri dersi 2017 öğretim programı, 2013 programı içeriğinde yapılan sadeleştirme ve içerik yoğunluğunun azaltılması işlemleri amaç edinerek oluşturulmuştur. Bu amaç doğrultusunda MEB (2017c) de Fen Bilimleri dersi 2017 öğretim programı için yapılan içerik düzenleme işlemleri maddeler halinde aşağıda belirtildiği gibi ifade edilmektedir:

- Güncel olmayan konuların müfredattan çıkarılması veya yeni bulunan bilgiler ışığında güncellenmesi,
- Farklı sınıflarda veya konu, ünite başlıkları altında tekrar eden aynı kazanımların azaltılması-çıkartılması,
- Öğrenci seviyesini üzerinde olan veya üst öğrenimlerde gösterilen içeriklerin çıkarılması,
- Kazanım açıklamalarına göre konuların/ünitelerin sınırlandırılması,
- İçerikleri ilişkili fakat başka konu veya ünitelerde olan başlıkların birleştirilmesi veya bir araya getirilmesi böylelikle öğrenmesin kolaylaştırılması,
- Farklı ünitelerde bulunan başlıkların birleştirerek yoğunluğun azaltılmasıdır.

2005 yılından itibaren gerek 2013 gerekse 2017 yılı fen dersi öğretim programı geliştirme çalışmalarında, yapılandırmacı öğrenme anlayışı benimsenmiştir. İçerik oluşturulmasında ise “sarmal yaklaşım” esas alınarak, düzenlemeler bu minval üzerine gerçekleştirilmiştir. Bu nedenle öğrenme alanlarındaki temel kavramlar tüm kademelerde dikkate alınmıştır. Sınıf düzeyi arttıkça bilgi, anlayış ve kazanımların yoğunluğu çoğalmış ve kapsamı ise genişlemiştir. Fen Bilimleri Dersi Öğretim Programı 3. sınıftan 8.sınıfa kadar incelendiğinde sarmal yapıda olmasının öğrencilerin hazırbulunuşluk seviyesine uygun olarak olumlu bir geçiş özelliği taşıdığı belirtilebilir. Bu durumda ilkokuldan itibaren bu yapının doğası gereği öğrencilerin Fen bilimleri dersinde gösterdikleri akademik başarının sürekliliğinin olması beklenmektedir. Bu nedenle üçüncü sınıftan itibaren öğrencilerin fen bilimleri ders başarıları (3, 4, 5, 6, 7, ve 8. sınıf) arasında pozitif ilişkinin beklenmesi, sınıf düzeylerine göre önceki fen bilimleri

ders başarılarının sonraki yıllardaki fen bilimleri ders başarısını yordama gücüne sahip olması beklenen bir durumdur.

Akademik Başarının Yordanması

Hedeflenen sonuca ulaşmak için gösterilen performans başarı olarak tanımlanmaktadır (Wolman, 1973; Akt: Aydoğan ve Zırhlıoğlu, 2018). Eğitiminin takdir ettiği notlar veya yapılan test sonuçlarıyla elde edilen sonuçlar veya her ikisi ile elde edilen sonuçlarla oluşan puanlar ise genellikle akademik başarı olarak tanımlanır (Carter ve Good, 1973; Özgüven, 2002). Ahmann ve Stanley Marvin'e (1971) göre bilişsel davranış gelişimleri akademik başarı olarak tanımlanır ve tanımlama yapılırken psikomotor ve duyuşsal gelişim gözardı edilir (Memduhoğlu ve Tanhan, 2013). "Akademik başarı", çoğunlukla öğrencinin okulla ilgili başarı durumunun harf, sayı vb. terimle ifade edilmesidir. Bazen tek dersin geçme derecesi veya derslerin ortalama notlarının ağırlıklı ders sayısına çarpılıp oluşan sayının tüm ders sayısına bölünerek çıkan sonuç veya bu sonucu ifade eden harfler akademik başarıyı ifade etmektedir (Gülleroğlu, 2005). Yukarıdaki tanımlara bakıldığında, başarı kavramına yüklenen anlamın iki boyutunun olduğu söylenebilir. Bunlardan birincisi, öğrencinin kazanıma ulaşmada gösterdiği performansı, yani süreci tanımlamada kullanılır iken, diğerinin ise öğrencinin kazanıma ulaşma derecesinin bir göstergesi olarak, daha çok sonuç ifadesi şeklinde "başarı" kavramının kullanıldığından söz edilebilir.

Eğitim süreçlerinde akademik başarı en çok önemsenen olgudur (Özgüven, 1998; Çitil, İspir, Söğüt ve Büyükkasap, 2006). Öğrencinin başarısı ve etkileri hakkında yapılan araştırmalarda "bilişsel alan" üzerinde yapılan incelemeler ağırlık kazanmaktadır (Akamca ve Hamurca, 2005; Altınok, 2005; Aydar ve Matyar, 2009; Ergin ve Ünal, 2006; Korkmaz ve Kaptan, 2001; Main, 1993; Taşdemir ve Tay, 2007; Tuan, Chin ve Shieh, 2005). Bu da duyuşsal ve psikomotor alandaki başarılarla yönelik çalışmaların azlığının bir göstergesidir.

Bununla beraber öğrencinin dersten başarılı sayılma durumuna etki eden değişkenlerin belirlenmesine ilişkin birçok bilimsel araştırmada yapıldığını da görmekteyiz. Başarılı sayılma durumuna etki eden değişkenlere bakıldığında ders çalışma alışkanlığı, kişilik yapısı, öz-yeterlik, motivasyon, öğrenme hızı, zekâ, benlik saygısı, zihinsel etmenler gibi duyuşsal alan incelemeleri ailenin sosyo-

ekonomik durumu, anne-baba tutumu, yönetici ve eğitimci yeterliliği veya tutumu gibi çevresel alan incelemeleri de dikkat çekmektedir (Arıcı, 2007; Howie ve Pieterston, 2001; Şevik, 2014; Wang, 2004; Akt: Sarier, 2016). Ulusal araştırmalarda, akademik başarıyı, öğrenciden, okuldan ve aileden kaynaklı bazı faktörlerin etkilediği belirlenmiştir (Sarier, 2016). Tüm bu çalışmalar bilişsel alandaki akademik başarıyı etkileyen değişkenlerin ortaya çıkarılmasında duyuşsal ve çevresel etkenlerin işe koşulması, akademik başarıya verilen önemin bir göstergesidir.

Akademik başarı kelimesi ile en sık kullanılan kelime ise “sınav” kavramıdır diyebiliriz. Sınav, öğrenci başarısını ölçmek için hazırlanan ortam olarak tarif edilebilir. Öğrencilerin, sınavlarda başarıları ölçülerek, onlar hakkında ulusal veya uluslararası düzeyde kararlar alınabilir (Özdemir, 2014). Aileler ve çevreleri başarının özellikle akademik başarının öğrencinin gelecek hayata, mesleki ve toplumsal yaşama daha dolu hazırlanmalarını sağladığından dolayı oldukça önemsemekteler (Yılmaz ve Tuncer, 2018).

Öğrencilerin gelecekteki başarılarını yordama gücü ve sınava giren öğrencilerin önceki öğrenmeleriyle olan ilişki düzeyi seçme sınavlarının geçerlilik düzeyini kanıtlayan özellikleridir (Aiken, 1971; Akt: Özdemir, 2014). Yordama, eldeki bilgiler ile gelecekte ne olacağı ile ilgili çıkarım yapmaktır. İstatistikî teknikler, bilinenlerden bilinmeyen hakkında çıkarım yapmaya ise istatistiksel açıdan yordama denir (Arıcı, 2001).

Yordama geçerliği, kişilerin test ile devam etmeyi planladığı eğitim programlarında veya çalışma hayatındaki yakalayacağı başarıyı önceden tahmin edebilmedeki oranını gösteren bir geçerlik ölçümüdür. Yordama geçerliği çalışmaları, karar öncesinde test sonuçları ile karar sonrası oluşan kıstas puanlarının arasındaki münasebeti tespit etmek için kullanılmaktadır. Dolayısıyla test sonuçlarında yüksek not alan kişilerin üst eğitim programlarında ve çalışma hayatında başarılı olacağı, test sonuçlarında düşük not alan kişilerin ise başarılı olamayacağı sonucuna varılır. Kişilerin ileride nasıl ve ne kadar başarılı olacağı bilinemez fakat iyi bir test yordama değerlendirilmesi yapılmasına imkân verir. Bundan dolayı test sonuçları ile kıstas puanlarının arasındaki münasebet, seçim ve yerleştirme yargılarının geçerliğinin bir ölçüsü olarak kullanılır (Thorndike, 1982; Akt: Özdemir, 2014).

Bu arařtırmada, öğrencilerin LGS (Liselere Giriř Sınavı) Fen Bilimleri dersi alt testinde yaptıkları doęru sayılarını yordadığı düşünölen; ilkokul 4. Sınıf ve ortaokul 5., 6., 7. ve 8. sınıf Fen Bilimleri dersi sınav notları birer yordayıcı deęişken olarak ele alınmıştır. Bu deęişkenlerin, LGS Fen Bilimleri Dersi başarısını ne derece yordadığının belirlenmesi ise arařtırmanın temel problemini oluřturmaktadır.

Genel olarak Türkiye’de okuyan öğrencilerin fen derslerindeki başarıları hem ulusal hem de uluslararası sınavlarda istenen düzeyde deęildir. Mesela Türkiye’nin fen başarı ortalamasının Uluslararası Fen ve Matematik Çalışması (TIMSS) ve Uluslararası Öğrenci Başarısını Deęerlendirme Programı (PISA) gibi uluslararası sınavların altında olduęu görölmektedir (Şişman, Acat, Aypay ve Karadaę, 2011). PISA 2015 raporuna göre Türkiye’nin fen puan ortalamaları Bulgaristan, Uruguay, Ürdün, Tayland ve Romanya gibi ölkeler ile kıyaslandığında aralarında anlamlı bir farkın olmadığı; Karadaę, Meksika, Endonezya, Arjantin, Brezilya gibi ölkelerle karşılaştırıldığında, daha iyi durumda olduęu, genel olarak bakıldığında ise, Türkiye 57 ölkede arasında 44. sırada olduęu görölmektedir (PISA, 2015). Latin Amerika, Orta Asya ve Afrika ölkeleri Türkiye’nin arkasında yer almaktadır. Bu durum; sosyal ve kültürel anlamda gelişmemenin eğitimdeki başarıyı da olumsuz etkilediğini göstermektedir. Yine uluslararası sınavlardan biri olan TIMSS en son 2015’te 50’den fazla ölkenin katılımı ile gerçekleştirilmiştir. TIMSS 2015 raporuna göre Türkiye 4. sınıf Fen Bilimleri başarısında, 47 ölkede arasında 483 ortalama puan ile 35. sırada; 8. sınıf Fen Bilimleri başarı ortalamasında ise 493 puanla 39 ölkede arasında 21. sırada yer almıştır. Türkiye’nin Fen Bilimleri ortalaması önceki döngölere göre sürekli bir artış göstermiştir (TIMSS, 2015). Bu uluslararası sınavlarda başarılarımızı artırmak için ulusal düzeyde müfredat ve sınav deęişikliğine gidilmiş olup (MEB, 2015), bilgi ve iletişim teknolojilerinin gelişmesiyle eğitim anlayışımızda da yenilikler yapılmıştır (Saęlam-Tosun, 2016). Bu yeniliklere ayak uydurmak için ulusal ve uluslararası düzeyde farklı sınıf seviyelerinde ölçme işlemleri yapılmaktadır. Türkiye’nin Fen Bilimleri dersi başarı ortalamasının düşük olmasında birçok sosyal ve kültürel birçok neden vardır. Bu nedenlerin neler olduęunun tespit edilmesi ve buna göre tedbirlerin alınması ölkemizdeki Fen Bilimleri dersi başarısının istenilen düzeylere gelmesi bakımından önemlidir (PISA, 2015).

Orta Öğretime Geçiş Sistemi

Bir sınav tekniği olan çoktan seçmeli test tekniği yıllardır değerlendirme sürecinde objektiflik sağladığı için eğitim sistemimizin önemli bir parçası olmuştur. Çoktan seçmeli test tekniği, büyük gruplara uygulanması ve kapsam geçerliliği konularında da kolaylık sağlamaktadır (Hündür, 2018). Ancak testlerde çok sayıda soru ile uygulanıp puanlanması kolay olmakla beraber soruların nitelikli olması ve niteliğin kazandırılabilmesi adına uzun bir hazırlık sürecinden de geçilmesi gerekir (Özçelik, 2010). Testin büyük avantajlarından biri hatta en önemlisi de her kademeye uygulanabilmesidir. Bunlarla beraber test uygulamalarında avantajların yanında dezavantajları da görünmektedir. Dezavantaj olarak bakıldığında çok geniş kapsamla uygulanması hatta tek yöntem olmalarına rağmen, üst düzey davranış ölçümlerinde yetersiz kalmaktadır (Atila ve Özeken, 2015). Temel eğitimin son sınıfında okuyan öğrenciler bireysel gelişimleri bakımından kendilerini kanıtlama, kimlik kazanma mücadelesinin yanında nitelikli eğitim kurumlarında eğitim-öğretim hayatına devam edebilmeleri gerekmektedir (Kısa, 1996; Kayapınar, 2006).

Ülkemizde öğrencilerin akademik yaşantıları merkezi sınavlara göre şekillenmekte bu da dolayısıyla gelecek yaşam, meslek seçimi hatta ikamet gibi hayat değişkenlerini değiştirebilmektedir. Sınavların yaşamımızda büyük rol oynadığı ve hayatımızı büyük ölçüde etkilediği görülmektedir (Hanımoğlu ve İnanç, 2011). Gelecekte iyi kariyere sahip olabilmek için bir üst kademeye geçiş sınavlarında iyi derece yapmak konusu önem arz etmektedir (Ocak, Akgül ve Yıldız, 2010).

Temel eğitimden orta öğretime geçmek için bir basamaklı veya daha fazla basamaklı olmak üzere yıllar içerisinde kaliteli bir eğitim kurumunda öğretim görmek isteyen öğrenciler için birçok sınav türü uygulanmıştır. Test usulü yapılan merkezi sınavların özdeki amacının geniş ölçekli olarak öğrencilerin gelecekteki başarılarını ölçmek olduğu söylenebilir (Başol ve Zabun, 2014). Ülkemizde denenen bu sınav türleri ile elde edilen sonuçlar öğrencinin öğrenim görmek istediği lise puanına ne derece sahip olup olmadığına bakılması, elde edilen sonuçların sınavdan önce gerçekleştirilen eğitim öğretim çalışmalarıyla birlikte bir bütün

olarak ölçme ve değerlendirmesinin yapılması en önemli halkalardan biri olarak görülmektedir (Özkan ve Özdemir, 2014).

Millî Eğitim Bakanlığı (MEB), zorunlu eğitim sürecinde ortaokulu bitiren öğrencilerin orta öğretime geçişinde geçmişten günümüze kadar birçok uygulama gerçekleştirilmiştir. Bu uygulamalardan biri olan ve 1988-1995 yılları arasında iki oturum şeklinde uygulanan Fen Liseleri Sınavı (FL), 1995'te yerini Fen Liseleri ve Anadolu Öğretmen Liseleri Sınavı'na bırakmıştır. (Dinç, Dere ve Koluman, 2014). Kesintisiz sekiz yıllık eğitimin (ilköğretimin) mecburi kılındığı yıllardan bu yana yapılan sınavları sıralarsak:

- Liselere Giriş Sınavı (LGS), 1997-2004 yılları arasında tek basamaklı ve isteyen öğrenciler için uygulanmıştır.
- Ortaöğretim Kurumları Seçme ve Yerleştirme Sınavı (OKS), 2004-2008 yılları arasında tek basamaklı ve isteyen öğrenciler için uygulanmıştır.
- Seviye Belirleme Sınavı (SBS), 2008-2013 yılları arasında 6, 7 ve 8.sınıflara üç sınav halinde isteyen öğrenciler için uygulanmıştır. Yenilenen öğretim programı nedeniyle vizyona uymamış ve önce sınav sayısı kademeli olarak azaltılmış ardından "Orta Öğretime Geçiş Sistemi" kapsamında yeni sisteme geçilmiştir.
- Temel Öğretimden Orta Öğretime Geçiş (TEOG), 12 yıllık kesintili eğitim sistemine geçişle beraber, 2013-2017 yılları arasında iki basamaklı ve tüm öğrenciler için uygulanmıştır.
- Son olarak kurgulanan sınav ise Liselere Geçiş Sınavı (LGS) ise 2017 yılında tek basamaklı olarak isteyen öğrencilere uygulanmaktadır (MEB, 2017).

Millî Eğitim Bakanlığı tarafından açıklanan, ortaöğretim kurumlarına geçişte uygulanmaya başlanan yeni modelde, eğitim bölgesi ve sınavsız mahalli yerleştirme sistemi getirilerek, "Veli Tercihine Bağlı Serbest Kayıt Sistemi" adı altında uygulanan yeni sistemle veli ve öğrenci adresine en yakın okulları tercih edebilmektedir. Yeni sistemle öğrencinin "sınav kaygısını" azaltarak isteyen öğrencilere sınavsız geçiş imkânı sağlanmaktadır. Sınava girmek istemeyen öğrenciler en az biri Mesleki Teknik veya İmam Hatip olarak tercih edecekleri beş okula belirli kriterlerle (yılsonu not ortalaması, devam devamsızlık gibi) sıralanarak sistem üzerinden kayıt olabilmektedirler. İsteyen öğrenciler ise LGS ile sınava

girerek aldıkları puan ile nitelikli olarak belirlenen Fen Liselerine, Sosyal Bilimler Liselerine, proje okulu olarak belirlenen Anadolu Liselerine, yine proje uygulamaları yapan Anadolu İmam Hatip ve Mesleki Teknik Liselerine tercih yapabilmekteler. Nitelikli okullara gitmek için sınava girmek isteyen öğrenciler ise haziran ayının ilk haftasında tek oturumda yapılacak olan Liseye Geçiş Sınavı'na gireceklerdir. Bu sınav sayısal ve sözel olarak temel dersleri içeren iki bölümden oluşmaktadır. Bu bölümler toplam 90 çoktan seçmeli sorudan oluşmaktadır. Soruların kapsamı 8. sınıf müfredatından hazırlanmaktadır. Sınav süresi toplamda 135 dakikadır. Öğrenciler sınava girmeden önce MEB tarafından eğitim-öğretim dönemi içerisinde örnek sorular yayınlanmaktadır.

Yapay Sinir Ağları

Günümüzde, teknolojik ilerlemelerin önemli seviyelere ulaşmasıyla birlikte insanoğlunun kendisini tanımasıyla ilgili çalışmaları da mühim ilerleme kaydetmiştir. İnsanın zihinsel becerilerinden olan düşünebilme ve öğrenebilme yetenekleri yapay zekâ kavramıyla önemli araştırma konuları durumuna gelmiştir. Yapay sinir ağları (YSA) teknolojisi, yapay zekâ çalışmaları çerçevesinde ortaya çıkan ve bir konuda yapay zekâ çalışmasını destekleyen farklı alanlardan biridir. Dolayısıyla, yapay zekâ alanının alt branşlarından biri olan yapay sinir ağları, öğrenebilen sistemlere temel teşkil etmektedir (Cevat, 2009). Yapay sinir ağları insan beyninin bilgiyi alma ve depolama becerilerini taklit etmesi üzerine geliştirilmiştir (Akgün, 2017).

Yapay Sinir Ağlarının Tanımı

YSA, insan beyninin yeteneklerinden olan öğrenme yoluyla yeni bilgiler elde edebilme, yeni bilgiler yaratma ve keşfedebilme gibi özellikleri herhangi bir yardım almadan otomatik olarak üretmek için geliştirilmiş bilgisayar sistemleridir (Öztemel, 2012). YSA için ortak karar verilmiş tek bir tanım yoktur. Bugüne kadar yapılmış geniş ya da dar kapsamda birçok tanım mevcuttur. Hatta bazı araştırmacılara göre yapay sinir ağının genel bir tanımını vermek yerine, çeşitlerinin kendi içinde tanımlanması gerekmektedir. YSA, en dar ve basit olarak, bir örnekler kümesi yardımıyla değişkenlerin uyarlanabilmesini sağlayacak bir matematiksel

formül amacıyla yazılan bilgisayar yazılımı olarak tanımlanabilir (Güneş, 2010). Daha kapsamlı ve genel kabul gören bir tanım ise Haykin tarafından verilmektedir: “Bir sinir ağı, basit işlem birimlerinden oluşan, deneysel bilgileri biriktirmeye yönelik doğal bir eğilimi olan ve bunların kullanılmasını sağlayan yoğun bir şekilde paralel dağıtılmış bir işlemcidir. Bu işlemci iki şekilde beyin ile benzerlik göstermektedir:

1. Bilgi, ağ tarafından bir öğrenme süreciyle çevreden elde edilir.
2. Elde edilen bilgileri biriktirmek için sinaptik ağırlıklar olarak da bilinen nöronlar arası bağlantı güçleri kullanılır” (Haykin, 1999).


Yapay Sinir Ağlarının Tarihçesi

1942 yılı yapay sinir ağları ile ilgili yapılan çalışmaların ve gelişiminin başlangıcı olarak kabul edilmektedir. Bu tarihte sinirbilimcisi (neuroscientist) olan McCulloch ve matematikçi Pitts, ilk hücre modelini geliştirmişlerdir. Bu çalışmada araştırmacılar, biyolojik sinir hücresinden esinlenerek temel biyolojik işlemleri yapabilen basit bir işlem birimi modeli gerçekleştirmişlerdir. Bununla beraber birkaç yapay hücrenin ara eşleşmesini incelediler. Hebb, 1949 yılında hücre ilişkilerini ayarlamak amacıyla ilk öğrenme kuralını önerdi. Rosenblatt, 1958 yılında algılayıcı (perceptron) modelini ve öğrenme kuralını geliştirerek; bugün kullanılan kuralların başlangıcını oluşturdu. Widrow ve Hoff tarafından, 1960-1962 yılları arasında ADALINE algoritması geliştirildi. 1969 yılında, Minsky ve Papert, algılayıcının mutlak analizini yaptı ve algılayıcının karmaşık lojik fonksiyonlar amacıyla kullanılamayacağını kanıtlamışlardır. Bu yüzden, yapay sinir ağları üzerine yapılan çalışmalar neredeyse durma noktasına gelmiştir. YSA’ların gelişiminde 1960 yılının ortalarını ve 1980 yılının başını kapsayan dönemde bir durgunluk dönemi yaşanmıştır. Yapay sinir ağlarının bilgi işlemede karşılaştığı zorluklar neticesinde yaşanan bu durgunluğun ardından geliştirilen günümüz bilgisayarlarının yarı iletken teknolojisi ile bilgi işlemeyi ucuz ve güvenilir hale getirmesi, çalışmalara tekrardan hız kazandırmıştır. 1982 yılında Hopfield YSA’nın birçok problemi çözebilecek yeteneği olduğunu göstermiş, optimizasyon gibi teknik problemleri çözmek için doğrusal olmayan Hopfield ağını geliştirmiştir. Kohonen, 1982-1984 yılları arasında öz düzenleme becerili haritayı (self-

organizing map) açıklamıştır. Kendi adıyla anılan bir eğitici-siz öğrenen ağ geliştirmiştir. 1986 yılında Rumelhart çok katmanlı geriye yayılım algoritmasını tekrar oluşturmuştur. 1988 yılında ise Chua ve Yang, hücresel sinir ağlarını geliştirmişlerdi (Güler, 2007). Daha sonraki kayda değer çalışmalar ise Boltzman makinesi, Yarışmacı Öğrenme Modeli, (Competitive Learning Model), Uyumlayıcı Rezonans Kuramı (Adaptive Resonance Theory) başlıkları altında yer alır. Son çalışmalar ise konuşma, görüntü işleme (image processing), anadil işleme (natural language processing) ve karar verme gibi problemlere açıklık getirebilecek düzeyde sinir ağları kapasitesini geliştirmede kullanılan bulanık mantık kavramlarıdır (fuzzy logic concepts). Temel olarak yapay sinir ağları ile; öngörü (tahmin), sınıflandırma, veri birleştirilmesi, veri kavramlaştırılması, veri süzülmesi, resim veya görüntü işleme (Elmas, 2011) alanları başta olmak üzere birçok uygulama yapılmış ve halen pek çok çalışma yapılmaya devam edilmektedir (Atalay, 2015).

Biyolojik Sinir Hücreleri ve Yapay Sinir Ağları

Beyinde bulunan hücreler insana düşünme, mantık ve deneyimlerini kullanma ve uygulama yeteneği sağlamaktadır (González ve DesJardins, 2002). Yapay sinir ağları insan beyninin bu yeteneklerinden faydalanarak, öğrenme yoluyla yeni bilgiler üretebilme, keşfetme ve oluşturma gibi özellikleri herhangi bir yardım almadan otomatik olarak gerçekleştirmeyi amaçlamaktadır (Çırak, 2012; Yavuz ve Deveci, 2012). Klasik bilgisayar algoritmaları ile yapay sinir ağlarının öğrenme algoritmaları birbirinden farklıdır. Çünkü öğrenme algoritmaları insan beynini yeteneklerini içinde taşırlar (Yavuz ve Deveci, 2012). Yapay sinir ağlarının çalışma prensibinin ve ağı oluşturan elemanların iyi anlaşılabilmesi için, biyolojik olarak bir sinir ağının nasıl çalıştığına bilinmesi önemlidir. Biyolojik sinir ağının temel yapı taşı olan ve sinir sistemiyle alakalı işlevleri yerine getiren basit bir sinir hücresi, nöron olarak tarif edilmektedir.



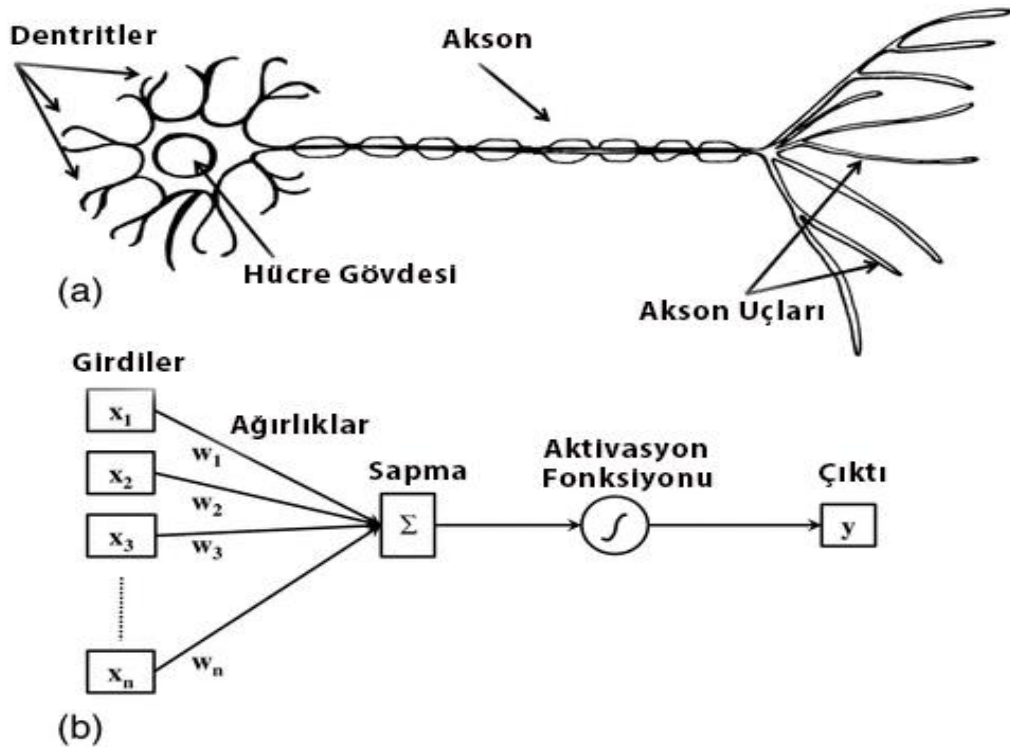
Şekil 2. Biyolojik sinir hücresinin yapısı.

Temel bir biyolojik sinir hücresi soma, akson, dendrit ve sinaps noktaları kısımlarından oluşmaktadır. Sinapslar, sinir hücrelerinin arasındaki bağlantılar olarak adlandırılır. Bunlar fiziksel irtibat değil, elektrik sinyallerinin bir hücreden diğerine geçmesine izin veren boşluklardır. İnsan beynindeki nöronlar takip edildiğinde nöronlar ya bir salgı bezi, ya bir kas ya da bir başka nöronla sonlanır. Aksondan bir başka nörona iletilen elektrik sinyali diğer nöronun dendritine, oradan somaya iletilir. Soma bunları işlemeye geçirir ve sinir hücresi kendi elektrik sinyalini oluşturur. Hücre bu sinyalleri sinapslara yollayarak diğer hücelere gönderilir. İki hücrenin birbirleriyle bilgi alışverişi sinaptik bağlantılardaki asetil kolin gibi kimyasal nörotransmitterler yardımıyla sağlanmaktadır. Şekil 2'deki akson uçlarının her biri, başka bir hücreyle irtibat halindedir (Öztemel, 2012). Şekil 3'te sinir sistemindeki bilgi akışı gösterilmiştir.



Şekil 3. Sinir sisteminde bilgi akışı (Yurtoğlu, 2005).

Yapay sinir ağlarının çalışma prensibinin ve ağı oluşturan elemanların biyolojik sinir hücreleri ile olan benzerliği Şekil 4'te gösterilmiştir. Hücreler arasındaki bağlantılar akson ve dendritlere; ağırlık faktörleri (W_k) sinapslara karşılık gelmektedir. Yapay sinir hücresinde, ağırlık faktörünün etkisine bağlı olarak ($W_{k1}, W_{k2}, \dots, W_{km}$) hücreye gelen uyarımlar (X_1, X_2, \dots, X_m) hücre içi sinaptik ağırlıkların durumu veya eğim de dikkate alınarak doğrusal olmayan bir aktivasyon fonksiyonu neticesinde çıktı şeklinde uyarıcıya dönüşür (Koç, Balas ve Arslan, 2004).



Şekil 4. Biyolojik ve yapay sinir ağlarının benzerliği

Şekil 4'te X_1, X_2, \dots, X_m nöron girişleridir. Her bir nöron girişi toplama işlemine girmeden önce W_1, W_2, \dots, W_n ağırlıklarıyla çarpılmaktadır. Toplam olarak, girişler X vektörü ile ağırlıklarıysa W vektörü ile gösterilebilir (Gülbağ, 2006). Birçok biyolojik sinir hücresinin bir araya gelmesi ve bağlantı kurmasıyla, yapay sinir ağı oluşmaktadır. Yapay sinir hücreleri, biyolojik sinir hücrelerinin basit bir modelidir. Tablo 2'de biyolojik sinir ağı ve YSA'nın karşılaştırması verilmiştir (Baş, 2006).


Tablo 1

Biyolojik Sinir Ağı ve YSA'nın Karşılaştırılması.

Biyolojik Sinir Ağı	Yapay sinir ağı
Sinir sistemi	Sinirsel hesaplama sistemi
Sinir hücresi (nöron)	İşlemci eleman (yapay sinir hücresi, düğüm)
Sinaps	İşlemci elemanlar arasındaki bağlantı ağırlıkları
Dendrit	Toplama fonksiyonu
Hücre gövdesi	Aktivasyon fonksiyonu
Akson	İşlemci eleman çıktısı

Yapay Sinir Ağlarının Yapısı ve Temel Bileşenleri

Biyolojik sinir hücrelerini taklit eden yapay sinir hücrelerinin birbirine bağlanmasıyla oluşan yapılar yapay sinir ağları denir. Yapay sinir ağları üç ana katmanda incelenir; Giriş Katmanı, Ara (Gizli) Katmanlar ve Çıkış Katmanı.



Şekil 5. Yapay sinir ağının genel yapısı.

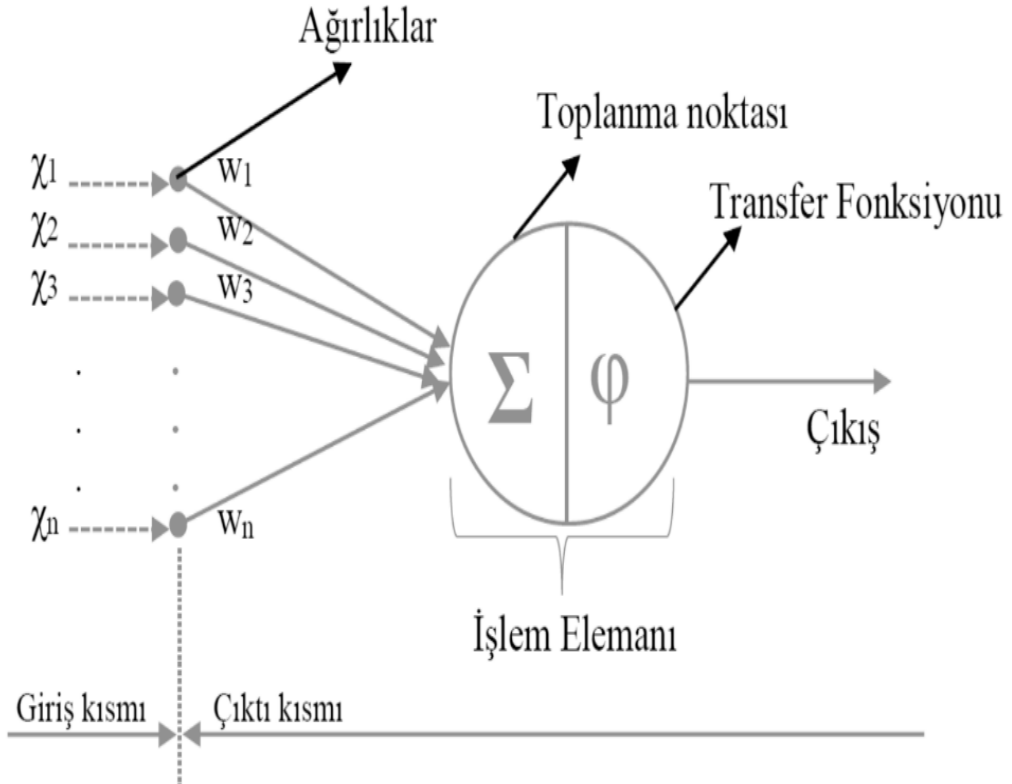
Giriş Katmanı: Bu katman bilginin ağıya tanıtıldığı ilk kısımdır. Girdi katmanında yer alacak nöron sayısı, bağımsız değişken sayısı kadardır. Bazı ağlarda girdi katmanında herhangi bir bilgi işleme uğramaz. Sadece girdi değerlerini bir sonraki katmana iletirler.

Ara (Gizli) Katman(lar): Girdi katmanından kendisine gelen bilginin işlenerek çıktı katmanına gönderildiği katmandır. Bu bilgilerin kaç alt katmanda

işleneceği ve her katmanda kaç nöron bulunacağını araştırmacı belirler. Bu sayının belirlenmesinde genellikle deneme yanılma yoluyla en iyi ağ performansını veren sayılar kullanılır. Ağın büyüklüğünün tanımlanması ve performansın bilinmesi açısından gizli katmanda bulunan nöronların sayısının seçimi oldukça önemlidir. Ayrıca gizli katman, yapay sinir ağında doğrusal olmayan ilişkileri modelleme gücünü kazandıran katmandır.

Çıkış Katmanı: Bu katmandaki nöronlar, gizli katmandan gelen bilgileri işleyerek ağın girdi katmanından sunulan girdi seti (örnek) için üretmesi gereken çıktıyı üretirler. Bu katmanda üretilen çıktılar dış dünyaya gönderilir.

Yapay sinir ağını oluşturan temel bileşenler; girdi katmanı, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktı katmanı olmak üzere beş farklı bileşenden oluşmaktadır (Akgün, 2017).



Şekil 6. Yapay nöronun genel yapısı.

- Girdiler, bir yapay sinir hücresine dış dünyadan veya diğer hücrelerden gelen bilgilerdir. Bu girdiler ağın öğrenmesi istenen örnekler tarafından

belirlenir. Yapay sinir hücresine dış dünyadan olduğu gibi diğer hücrelerden veya kendi kendisinden de bilgiler gelebilir. Bir nöron genellikle eşanlı olarak çok sayıda girdi alabilir. Her girdinin kendi nispi ağırlığı vardır (Öztemel, 2012; Yurtoğlu, 2005; Baş, 2006;).

- Ağırlıklar, bir yapay sinir hücresine gelen bilginin önemini ve hücre üzerindeki kuvvetini gösterirler. Şekil 6'daki ağırlık 1 (w_1), girdi 1 (x_1)'in hücre üzerindeki etkisini göstermektedir. Ağırlıkların büyük ya da küçük değerler alması önemli veya önemsiz olduğu anlamına gelmez. Artı veya eksi olması, etkisinin pozitif veya negatif olduğunu gösterir. Sıfır olması ise herhangi bir etkinin olmadığını gösterir. Ağırlıklar değişken veya sabit değerler olabilirler. Yapay sinir ağı içinde girdilerin nöronlar arasındaki iletimini sağlayan tüm bağlantıların farklı ağırlık değerleri bulunmaktadır. Böylelikle ağırlıklar, her nöronun her girdisi üzerinde etki yapmaktadır (Öztemel, 2012; Yurtoğlu, 2005; Baş, 2006).
- Toplama Fonksiyonu; bir hücreye gelen net girdiyi hesaplayan bir fonksiyondur. Bunun için değişik fonksiyonlar kullanılmakla beraber en yaygın olanı ağırlıklı toplamı bulmaktır. Burada her gelen girdi değeri kendi ağırlığı ile çarpılarak toplanır. Böylece net gelen girdi bulunmuş olur. Ancak bazı durumlarda toplama fonksiyonu bu kadar basit bir işlem olmayabilir. Bunun yerine, en az (min), en çok (max), mod, çarpım, çoğunluk veya birkaç normalleştirme fonksiyonu gibi çok daha karmaşık olabilir. Girdileri birleştirecek olan algoritma, genellikle seçilen ağ mimarisine de bağlı olarak belirlenir. Bu fonksiyonlar farklı şekilde değerler üretebilir ve bu değerler ileri doğru gönderilir. Herhangi bir nöronunun toplam girdisi, diğer nöronlardan gelen değerlerin ağırlıklı toplamı ile eşik değerinin toplamına eşittir (Öztemel, 2012; Yurtoğlu, 2005; Baş, 2006;).

Tablo 2

Toplama Fonksiyonu Örnekleri

Toplam	$NET = \sum_i^n w_{ij} x_i + \theta_j$
Çarpım	$NET = \prod_i w_{ij} x_i$
Minimum	$NET = \text{Min} (w_{ij} x_i)$
Maksimum	$NET = \text{Max} (w_{ij} x_i)$
Çoğunluk	$NET = \sum_i^n \text{Sgn} (w_{ij} x_i)$

*Kaynak: Öztemel, 2012.

- Aktivasyon (Transfer) Fonksiyonu; Toplama fonksiyonu ile elde edilen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirleyen fonksiyondur. Aktivasyon fonksiyonunun kullanım amacı, zaman söz konusu olduğunda toplama işlevinin çıkışının değişmesine izin vermesidir. Hücrenin gerçekleştireceği işleve göre çeşitli tipte aktivasyon fonksiyonları kullanılabilir. Mesela çok katmanlı algılayıcı modellerinde aktivasyon fonksiyonunun türevi alınabilir bir fonksiyon olması gerekmektedir. Aktivasyon fonksiyonun seçimi, büyük ölçüde yapay sinir ağının verilerine ve ağın neyi öğrenmesinin istendiğine bağlıdır. Genelde seçilen aktivasyon fonksiyonu, doğrusal değil, doğrusal olmayan bir fonksiyondur. Çünkü doğrusal fonksiyonlarda çıktı, girdi ile orantılıdır. Bir problem için en uygun fonksiyon tasarımcının denemeleri sonucunda belirlenmektedir. Tablo 3'te literatürde kullanılan bazı aktivasyon fonksiyonları verilmektedir. Günümüzde en yaygın olarak kullanılan Çok Katmalı Algılayıcı modelinde ise aktivasyon fonksiyonu olarak sigmoid fonksiyonu veya hiperbolik tanjant fonksiyonu tercih edilmektedir.

Tablo 3

Bazı Aktivasyon Fonksiyonu Örnekleri.

Aktivasyon Fonksiyonu	Matematiksel Gösterimi	Matematiksel Gösterimi
Lineer Fonksiyon	$F(\text{NET}) = \text{NET}$	
Step Fonksiyonu	$F(\text{NET}) = \begin{cases} 1 & \text{eğer } \text{NET} \geq \theta \\ 0 & \text{eğer } \text{NET} < \theta \end{cases}$	
Sigmoid Fonksiyonu	$F(\text{NET}) = \frac{1}{1 + e^{-\text{NET}}}$	
Hiperbolik Tanjant Fonksiyonu	$F(\text{NET}) = \frac{e^{\text{NET}} + e^{-\text{NET}}}{e^{\text{NET}} - e^{-\text{NET}}}$	
Eşik Değer Fonksiyonu	$F(\text{NET}) = \begin{cases} 0 & \text{eğer } \text{NET} \leq 0 \\ \text{NET} & \text{eğer } 0 < \text{NET} < 1 \\ 1 & \text{eğer } \text{NET} \geq 1 \end{cases}$	

- Yapay Sinir Hücresinin Çıktısı; aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Üretilen çıktı dış dünyaya veya başka bir hücreye gönderilir. Hücre kendi çıktısını kendisine girdi olarak da gönderebilir. Aslında bir nöronun çıkan tek bir çıktı değeri vardır. Aynı değer birden fazla nörona girdi olarak gitmektedir (Öztemel, 2012).

Yapay Sinir Ağlarının Genel Özellikleri

Yapay sinir ağlarının karakteristiği yapılacak olan uygulama ile belirlenmektedir, bu yüzden yapay sinir ağlarının çok sayıda farklı çeşitleri vardır. Burada bütün modeller için geçerli olan genel karakteristik özellikler aşağıdaki gibi sıralanabilir (Öztemel, 2012);

- Yapay sinir ağları makine öğrenmesi gerçekleştirirler. Yapay sinir ağlarının temel işlevi bilgisayarların öğrenmesini sağlamaktır. YSA, olayları öğrenerek benzer olaylar karşısında mantıklı kararlar vermeye çalışırlar.
- Yapay sinir ağları örnekleri kullanarak öğrenirler. YSA'nın olayları öğrenebilmesi ve doğru tahmin edebilmesi için o olayla ilgili örneklerin belirlenmesi gerekmektedir. YSA'lar örnekleri kullanarak ilgili olay hakkında genelleme yapabilecek yeteneğe ulaştırılırlar (adaptif öğrenme). Ağın başarısı seçilen örnekler ile doğru orantılıdır, ağa olay bütün yönleri ile gösterilmezse ağ yanlış çıktılar üretebilir.
- YSA'ların yazılımları, çalışma tarzı bilinen programlama yöntemlerine benzememektedir. Geleneksel programlama ve yapay zekâ yöntemlerinin uygulandığı bilgi işleme yöntemlerinden tamamıyla farklı bir bilgi işleme yöntemi vardır.
- Yapay sinir ağlarında bilgi, ağın bağlantılarının değerleriyle ölçülmekte ve bağlantılarda saklanmaktadır.
- Görülmemiş örnekler hakkında bilgi üretebilirler. Ağ kendisine gösterilen örneklerden genelleme yaparak görmediği örneklere ilişkin de bilgiler üretebilmesi sağlanabilir.
- Algılamaya yönelik durumlarda kullanılabilirler. Ağlar genellikle algılamaya yönelik bilgileri işlemede kullanılırlar. Bilgiye dayalı çözümlerde uzman sistemler kullanılmaktadır ve bazı durumlarda yapay sinir ağı ve uzman sistemler birleştirilerek daha etkin sistemler kurulabilir.
- İlişkilendirme ve sınıflandırma yapabilirler. Genel olarak ağların büyük kısmının amacı kendisine örnekler halinde verilen örüntülerin kendisi veya diğerleriyle ilişkilendirilmesidir.
- Örüntü tamamlama gerçekleştirebilirler. Eğitilmiş ağa birtakım durumlarda eksik örüntü veya şekil verilerek ağın bu eksik bilgileri

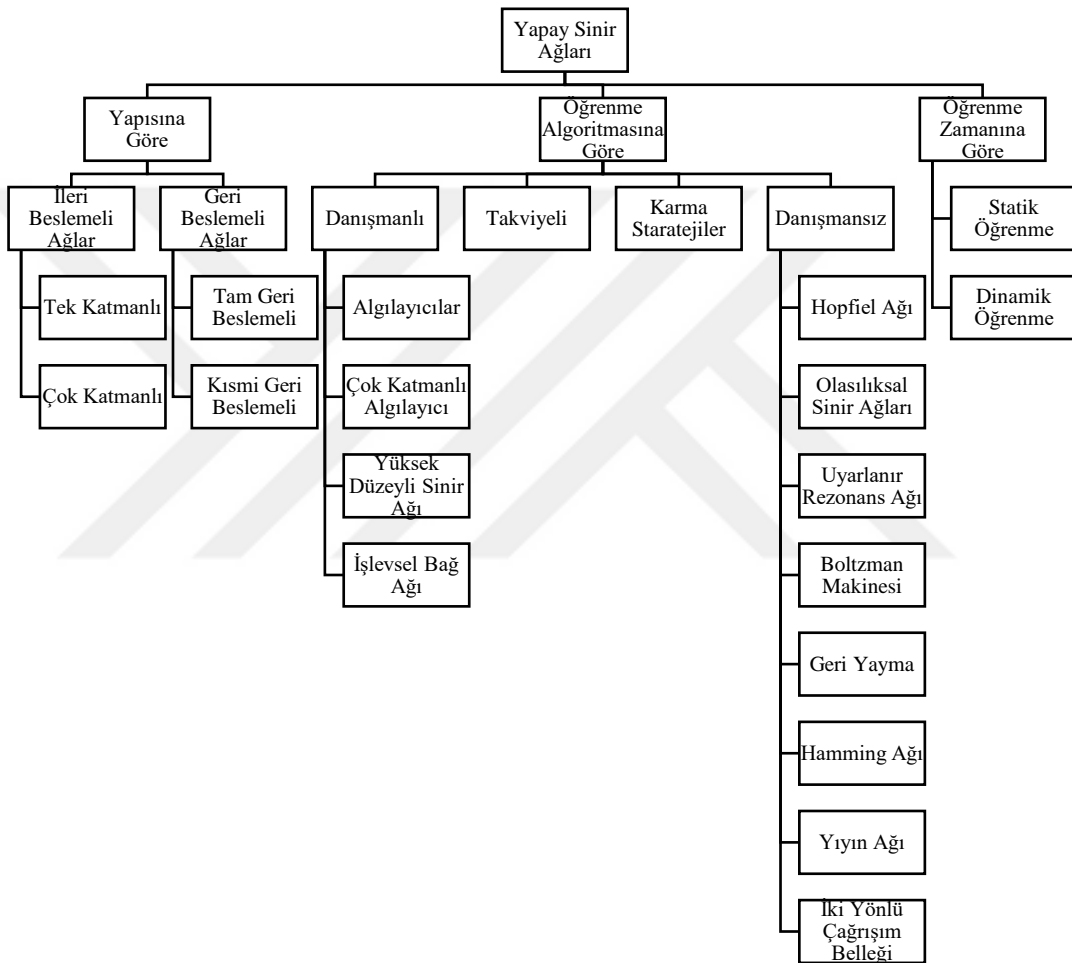
tamamlaması beklenir. Örneğin fotoğrafın yarısı ağa verilir ve ağın fotoğrafı tamamlayıp kime ait olduğunu söylemesi beklenir.

- Kendi kendini organize etme ve öğrenebilme yetenekleri vardır.
- Eksik bilgi ile çalışabilmektedirler. Geleneksel sistemlerin tersine yapay sinir ağları eğitildikten sonra veriler eksik bilgi içerse dahi, çıktı üretebilirler. Bu durum bir performans kaybı yaratmaz ve performans kaybı eksik bilginin önemine bağlıdır. Burada bilginin önem derecesi eğitim aşamasında öğrenilir.
- YSA'nın hata toleransı vardır. Yapay sinir ağının eksik bilgilerle çalışabilme yetenekleri, hatalara karşı toleranslı olmalarını sağlamaktadır. Ağın bazı hücreleri bozulsa ve hatta çalışamaz duruma gelse bile ağ, çalışmaya devam eder.
- Dereceli bozulma gösterirler. Yapay sinir ağlarının hatalara karşı toleranslı olmaları bozulmalarının da dereceli olmasına sebebiyet vermektedir.
- Dağıtık belleğe sahiptirler. Yapay sinir ağlarında bilgi ağa dağılmış bir biçimde tutulur. Hücrelerin bağlantı ve ağırlık dereceleri, ağın bilgisine karşılık gelir. Bu yüzden tek bir bağlantının kendi başına anlamı yoktur.
- Yapay sinir ağlarının güvenli çalıştırılabilmesi için performans testine ihtiyaç duyarlar. Yapay sinir ağlarında eğitim ve test aşamasına yönelik iki ayrı örnek setleri oluşturulur. Birincisi ağı eğitmek için diğeri de ağın performansını sınamak için kullanılır. Her ağ önce eğitim setiyle eğitilir. Ağ bütün örneklerle doğru cevaplar vermeye başladığı zaman eğitim işi tamamlanmış kabul edilir. Daha sonra ağın test setindeki hiç görmediği örnekler ağa gösterilerek ağın verdiği cevaplara bakılır. Eğer ağ hiç görmediği örneklerle kabul edilebilir doğrulukta cevaplar veriyorsa, ağın performansı iyi kabul edilir. Ağın performansı yetersizse yeniden eğitmek veya yeni örneklerle eğitmek gibi bir çözüme gidilir.

Burada açıklanan özellikler dikkatle incelendiğinde, aslında YSA'ların bilgisayar bilimine oldukça avantajlı katkılarının olduğu söylenebilir. Geleneksel bilgisayar yazılım teknolojisiyle çözülemeyen birçok problemin YSA ile çözülebileceği görülebilir. Örneğin YSA'lar için eksik, normal olmayan, belirsiz bilgileri işleyebilen en güçlü problem çözme tekniğidir, demek yanlış olmaz (Öztemel, 2012).

Yapay Sinir Ağlarının Sınıflandırılması

Literatürde yapay sinir ağlarının kategorize edilmesinde birden fazla özellik gözetilerek öğrenme algoritmalarına (yöntemlerine), besleme yönüne veya ağ yapılarına göre farklı sınıflandırmalar yapılmaktadır (Haykin, 2009; Heaton, 2008; Turhan, Kurt ve Engin, 2013). Bu sınıflandırmalardan en çok kullanılanlarına aşağıda değinilmiştir.



Şekil 7. Yapay sinir ağlarının ağ yapıları

Yapay sinir ağlarının öğrenme algoritmasına göre sınıflandırılması

En iyi ağırlık kümesini bulmaya yardım eden birçok öğrenme algoritması ileri sürülmüştür. Yapay sinir ağlarında kullanılan öğrenme algoritmaları danışmanlı (öğretmenli), danışmansız (öğretmensiz), destekleyici (takviyeli) ve

bunların birkaçının bir arada kullanılmasıyla elde edilen karma öğrenme algoritmaları olmak üzere dört çeşitten oluşmaktadır (Akgün, 2017).

Danışmanlı (öğretmenli) öğrenmede, sisteme dışarıdan bir öğretici müdahalesi söz konusudur. Girdi verileriyle birlikte sisteme istenen çıktı değerleri verilerek, ağı bu durumu öğrenmesi sağlanır (Yavuz ve Deveci, 2012). Bu sayede ağ, girdi-çıkıtı arasındaki ilişkileri öğrenir bir sonraki ağı işe koşulmasında bu ilişkiler ağına göre çıktılar üretir tahminde bulunur. Tahmin edilen veri ile gerçek veri arasındaki benzerlik ne kadar fazla ise, ağ o kadar iyi öğrenmiş kabul edilir.

Danışmansız (öğretmensiz) öğrenmede, danışmanlı öğrenmedeki gibi girdi verileri sisteme verilir. Ancak farklı olarak, çıktı değerleri sisteme dâhil edilmez. Ağ tarafından üretilen çıktıların birçok sınıfa dâhil olduğu kabul edilir ve ağı eğitim süreci, eğitim verilerinin ayırt edici özelliklerinin bulunmasından ibarettir (Cura, 2004).

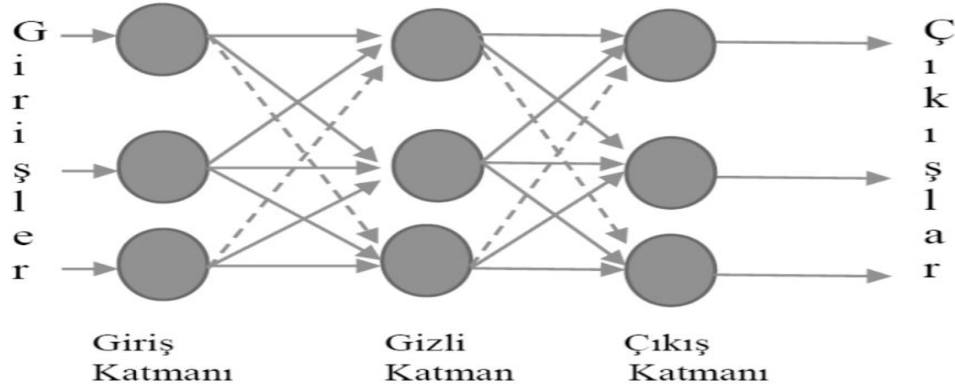
Destekleyici öğrenmede ise, öğretmenli öğrenmede olduğu gibi ağı bir öğretmen yardımcı olur. Fakat burada öğretmen, olması gereken çıktıları sisteme tanıtmaz. Bir girdi vektörüne karşılık ağı ürettiği çıktı için olumlu veya olumsuz sinyal üretilerek, ağ ağırlıklarının düzenlenmesi sağlanır.

Yapay sinir ağlarının yapısına (besleme yönüne) göre sınıflandırılması

Yapay sinir ağlarında besleme yönü ileri beslemeli ve geri beslemeli olmak üzere ikiye ayrılmaktadır. Burada besleme yönü ile kastedilen, ağı öğrenme aşamasında girdi ve çıktı verileri arasında yaşanan öğrenme ve örüntü oluşturma sürecinde gösterdiği ilerlemenin yönüdür.

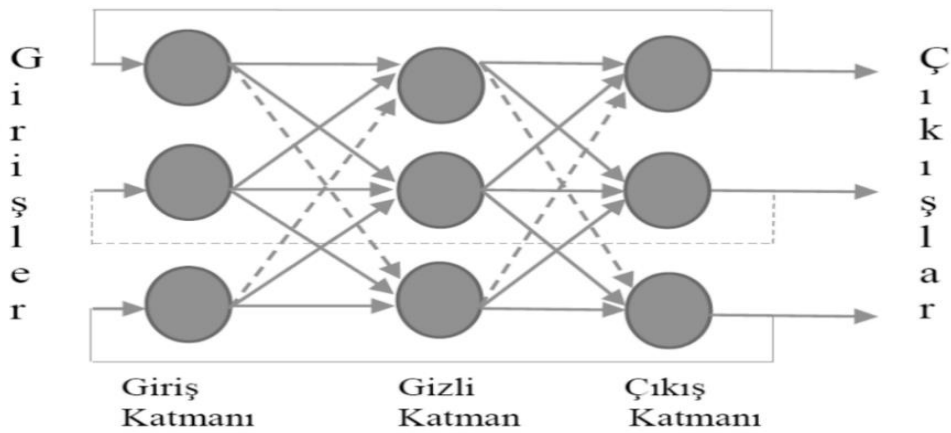
İleri beslemeli yapay sinir ağlarında; nöronlar giriş katmanından çıkış katmanına doğru düzenli katmanlar şeklindedir ve bir katmandaki nöronların çıkışları bir sonraki katmana ağırlıklar üzerinden giriş olarak verilir (Fırat ve Güngör, 2004). Bu tip ağlarda işlem yönü ileriye doğrudur, geriye doğru herhangi bir işlem bulunmamaktadır (Adhikari ve Agrawal, 2014). Bu nedenle ileri beslemeli yapay sinir ağlarında nöronlar arasındaki bağlantılar bir tekrar oluşturmamakta ve bu ağlar girilen verilerden hızlı bir şekilde çıktı üretebilmektedir. Desen /örüntü

tanıma, sinyal işleme ve sınıflandırma gibi problemlerde genellikle bu metodoloji kullanılır (Baş, 2006).



Şekil 8. İleri beslemeli yapay sinir ağının yapısı.

Geri beslemeli yapay sinir ağları; genellikle denetimsiz öğrenme ilkelerinin uygulandığı ağlarda kullanılmaktadır (Cura, 2004). Bu ağ yapılarında girdi ile çıktı katmanları arasında bilgi iletimi sadece tek yönlü değildir. Gizli katmanda ya da çıktı katmanındaki çıkışların önceki katmanlardan da beslendiği bir geri beslemeli ağ yapısı vardır. Dolayısıyla bir sinirin çıkışı, sinirin o andaki girdileri ve ağırlık değerleriyle belirlenmesinin yanında bazı sinirlerin bir önceki katmanlardaki çıkış değerlerinden de etkilenmektedir (Çırak, 2012). Geri beslemeli sinir ağları bu özellikleri ile önceden tahmin uygulamaları için uygun sonuçlar sunmaktadır (Kayıkçı, 2014). Basit bir geri beslemeli sinir ağının şekil 9 da gösterimi şu şekildedir;



Şekil 9. Geri beslemeli yapay sinir ağının yapısı.

Yapay sinir ağlarının öğrenme zamanına göre sınıflandırılması

Yapay sinir ağları öğrenme zamanına göre, statik ve dinamik öğrenme olmak üzere iki grupta toplanabilir.

Statik öğrenme prensibi ile çalışan suni sinir ağları kullanmadan önce öğrenim işlemine maruz kalmaktadır. Eğitimin tamamlandıktan sonrasında ağ istenilen halde kullanılabilir. Ama kullanım sırasında ağın üzerindeki ağırlıklarda hiçbir farklılık olmamaktadır (Tok, 2017).

Dinamik öğrenme prensibi ile çalıştığı zaman zarfında öğrenmesini önceden tahmin ederek modellenmiştir. YSA eğitim aşaması tamamlandıktan sonra ya da daha sonraki kullanımlarında çıkışların onayına bakılırsa ağırlıklarının farklılaştırarak çalışmaya devam etmektedir (Güney, 2009).

Yapay Sinir Ağlarının Kullanım Alanları

Günümüzde yapay sinir ağlarının yeteneklerinden ötürü sayılamayacak çok alanda kullanılmaktadır. Tahmin, sınıflandırma, veri ilişkilendirme, veri filtreleme, tanıma ve eşleştirme, teşhis ve yorumlama problemlerinde yapay sinir ağları çok yaygın şekilde kullanılır. Yapay sinir ağlarının kullanım alanları aşağıdaki gibidir (Demirceylan, 2012; Hamzaçebi, 2011):

- Tahmin: Herhangi bir değişkeninin gelecekte alacağı değerler bilinmediği zaman, değişkenin geçmişteki davranışlarından yola çıkarak gelecekte alacağı değerler tahmin edilmeye çalışılır. Örneğin; satışların ne kadar olacağı, nüfus tahmini, belli bir mal veya hizmete talebin ne olacağını bilirmek istediği durumlar (Hamzaçebi, 2011).
- Sınıflandırma: Sınıflandırma herhangi bir nesnenin birden çok sınıf içerisinde hangi sınıfa ait olduğunu belirleme işlemidir. YSA'lar el yazısı ya da baskı yazı karakterlerinin ayırt edilmesi, kredi verme işlemlerinde müşterilerin riskli veya risksiz gibi tanımlanması vb. birçok işlemde kullanılmaktadır (Hamzaçebi, 2011).
- Kümeleme: Kümeleme birbiriyle benzerlik gösteren nesnelere bir gruba toplamaktır (Hamzaçebi, 2011).

- Örüntü tanıma: Bozuk veya eksik örüntülerin, YSA'ya tanıtılmış örüntülerle karşılaştırarak bozuk örüntünün doğrusunun elde edilmesi sağlanır (Hamzaçebi, 2011).
- Fonksiyon yaklaşımı: Çoğu hesaplama modeli, belli girdilere karşılık belli çıktıların alındığı uygun fonksiyonlarla ifade edilebilirler (Hamzaçebi, 2011).
- Optimizasyon: Birçok bilimsel veya işletme ve endüstri problemleri, belli kısıtlar altında bir amacın uyumlu hale getirildiği problemler şeklinde ifade edilebilir. Örneğin gezgin satıcı problemi Hopfield ağı ile modellenip çözümlenebilir (Hamzaçebi, 2011).
- Veri filtreleme: Görmek ya da kullanmak istemediğimiz verilerin olduğu ağlar birçok veri arasında uygun verileri seçme görevi ile ilgili gerekeni yaparlar. Telefon konuşmalarındaki gürültüyü asıl konuşmalardan ayıran ağlar bu duruma örnektir (Öztemel, 2012).

Araştırmanın Tanımları

Öğretim programı: Bir dersin öğrencilere formal veya informal öğretimle kazandırılması düşünülen ve etkinliklerin tamamını içine alan planlamadır.

Fen Dersi Başarısı: Öğrencilere fen dersinde ders öğretmenleri tarafından, ölçme ve değerlendirme aracı olarak kullanılan, öğrencilerin kazandıkları bilgi ve becerilerin ifadesi olarak verilen yazılı sınav başarı puanları.

LGS Fen Bilimleri Alt Testi: Liselere Geçiş Sınavında yer alan 20 adet Fen Bilimleri dersine ait soruları ifade eder.

Yapay Sinir Ağı: Biyolojik sinir ağını hem fizyolojik yapısı ve hem de fonksiyonları açısından modellemeye çalışan bir sayısal problem çözme yöntemidir.

MATLAB: Teknik hesaplama açısından yüksek bilim adımları için verileri analiz et, algoritmalar geliştirme, model ve uygulamalar oluşturmak için özel olarak tasarlanmış bir programlama platformudur. Matris tabanlı ve vektör formülasyonları ile özellikle birçok teknik bilgi işlem sorunlarını hızlı çözüme kavuşturan dildir. C, C++, Fortran, Java gibi programlama dilleri ve MS Excel ile

tümleşik çalışabilmektedir. Gerçek dünya varlıklarının dijital ortamda ifade edilmeleri sağlanabilir ve kontrol sistemleri geliştirilebilir.

Girdiler: İstatistiki analizlerde bağımsız değişkenler olarak ifade edilen ve bu araştırmada akademik başarıyı etkilediği düşünülen sınav başarı puanlarını içeren parametrelerdir.

Çıktılar: İstatistiki analizlerde bağımlı değişkene karşılık gelen değişkenleri olarak ifade edilen ve bu araştırmada çıktı değişkeni olarak LGS sınavı Fen Bilimleri alt testi yapılan doğru sayılarını içeren parametrelerdir.

Problem Durumu

Ülkemizde fen bilgisi dersi, öğretim programı geliştirme faaliyetlerine paralel olarak, içerikle birlikte isim değişikliğine de uğramıştır. Fen bilgisi adı altında yürütülen ders daha sonra fen ve teknoloji son olarak da fen bilimleri ismi altında öğretim programlarında yer almaktadır. İsim ve içerik değişikliğinin yanında önemli bir değişimde, dersin başlangıcının sınıf düzeyinde yapılan değişikliktir. İlkokul 4. sınıftan itibaren okutulan fen bilimleri dersi 2013 yılından itibaren ilkokul 3. Sınıf düzeyinde okutulmaya başlamıştır. Böylelikle çocukların fen/bilim kavramıyla tanışmaları daha erkene alınmıştır. Fen bilimleri dersi, temel eğitim çağında veya ilköğretimi kapsayan ilk ve ortaokul dönemlerinde öğrenciyi üst öğretime hazırlayıcı önemiyle beraber gelecek zamana ve gelecek hayata hazırlama gibi öneme de haizdir (Zinicola, 2003). Fen okur-yazarı kişilerin yetiştirilmesi fen öğretiminin asıl gayelerindendir (De Boer, 2000). Fen okur-yazarlığı, bireylerin eleştirel düşünme, araştırma-sorgulama, problem çözme ve karar verme becerileri geliştirmeleri, yaşam boyu öğrenen bireyler olmaları, etraflarındaki dünya hakkındaki merak duygularını sürdürmeleri için gerekli olan fenle ilgili beceri, tutum, değer, anlayış ve bilgilerinin bir birleşimidir (Kavak, Tufan ve Demirelli, 2006). Fen eğitiminin önemini ifade ederken, fen eğitiminin kişilerin ihtiyaçlarının giderilmesinde ön planda olduğunu vurgulamıştır. Yine, kişilerin hem hayatta karşılaşacakları sorunları çözümlenmede hem de toplumun diğer fertlerinin ihtiyaçlarını karşılayarak daha kaliteli yaşam standartlarına ulaşmasında fen eğitiminin önemli katkı sağlayacağını ifade etmiştir. Çünkü bireyler, bireyler fen dersiyle özellikle düşünme becerisini geliştirip, gerçek

yaşamını anlar ve toplumsal yaşama daha rahat ayak uydurur. Bu gelişmeler için de bireylerin fen dersindeki başarısı önemli olarak görülmektedir.

Eğitim ile ilgili çalışmalarda ortak amaç öğrencinin başarısıdır. Bu nedenle araştırmalar genellikle öğrencilerin başarılarının nasıl geliştirileceğine odaklanır. Başarı, motivasyon kazanmak, belirli yöntemlerle ve belirli zaman aralığında beklenenin elde edilmesi şeklinde tanımlanabilir. Demirtaş ve Güneş (2002) de eğitim açısından başarıyı, program amaçlarına uygun davranış bütünü olarak tanımlar. Başka açıdan kişinin başarı sağlaması öğretim esnasında kazandırılmaya çalışılan hedef ve davranış oranıyla ila alakalıdır. Okul başarısı ise eğitim-öğretim programında bulunan derslerin not veya puan ortalamasıdır (Özguven, 2002). “Akademik başarı” öğretmenlerin derslerde öğrenciye sınav, performans, proje gibi kriterlerle belirli kriter ve/veya kazanım bilgilerine takdir ettikleri notlar olarak tanımlanmaktadır (Carter ve Good, 1973). En genel anlamda akademik başarı akademik süreçte önceden belirlenmiş gayelere varma notunu ifade eder. Akademik başarı faktörünün eğitim sürecinin bir işareti olarak ifade edilmesi, eğitimde önemli ve farklı açılardan yorumlamıştır. Akademik başarının eğitim ve öğretim süreçlerine etkisi bu bağlamda önemli bir paya sahiptir. Akademik başarı çoğunlukla okullarda veya eğitim kurumlarında gösterilen derslerde edinilen bilgi ve becerilerin ölçülmesi için uygulanan sınavlarla oluşturulmaktadır (Sünbül ve Gürsel, 2001).

Sınavlara eğitimin kalitesi ölçümünde çoğunlukla başvurulmakta, öğrenci başarısının yorumlanması sonunda önemli kararlar alınabilmektedir. Özellikle bu değerlendirme süreci ulusal ve/veya uluslararası (PISA vb.) düzeyinde olabilmektedir. Öğrenme düzeylerinin belirlenmesi için kazanım değerlendirme ve izleme sınavları da uygulanmaktadır. Bu uygulamalar okul, bölge, ilçe ve il düzeylerinde seviye tespit sınavları adı altında uygulanmakla beraber, uluslararası düzeylerde de belirli sıklıklarla yapılmaktadır. Ulusal düzeyde yapılan uygulamaların çoğunluğu üst öğrenime öğrenci seçmek amacıyla uygulanmaktadır. Örneğin temel eğitimden ortaöğretime geçişte son olarak kullanılan sistem “Liselere Geçiş Sınavı” (LGS), ortaöğretimden yükseköğretime geçişte de “Yüksek Öğretim Kurumları Sınavı” (YKS) kullanılmaktadır. Ülkemizde uygulanan seçme sınavlarında, öğrencilerin üst öğrenimde geçeceği bölüm veya okul türünü belirlemek ve öğrenciler arası yeterli niteliğe göre sıralama yapmak

amaçlanmaktadır. Bu amaçlara ulaşabilmek için sınavların geçerliği, güvenilirliği ve kullanılabilirliği gibi özellikler göz önüne alınmalıdır. Seçme sınavlarda ki amaç, öğrencinin bir üst öğrenimde daha başarılı olma ihtimalinin fazla olanı seçmek olduğundan, bu tarz sınavlarda bulunması gereken en önemli özellik yordama geçerliliğidir. Bu amaç doğrultusunda çoğunlukla öğrencinin eğitim aldığı okuldaki veya kurumdaki performansına göre ölçülür. Öğrencinin gelecek eğitimlerdeki başarılarının yordama gücü ile öğrencinin daha önce bulunduğu öğrenme durumları ile olan ilişki düzeyi, seçme sınavlarının geçerlilik kanıtı olmaktadır (Aiken, 1971; Özçelik, 1998; Baykul, 2000). Bu çalışmanın merkezinde de öğrencilerin fen bilimleri dersindeki akademik performanslarının yapay sinir ağları ile tahmin edilmesi yer almaktadır.

Gelişen teknoloji ile bilgisayar sistemleri hayatımızın önemli bir yerini teşkil etmekte olduğu bugünlerde insanlar gibi yeni öğrenmeler yaparak, karar verme yetenekleri hızla gelişmekte ve hızla da yaygınlaşmaktadır. Yapay zekâ ile tanımlanan bu sistemler matematiksel olarak ifade edilemeyen ve insanların çözmesinin imkânı olmayan durumları çözümlenmektedir. Yapay zekâlar, sorunlara ve olaylara yeni çözümler yaparken, bilgisayarın öğrendiği örnek, tecrübe ve simülasyonlardan, yeni bilgiler edinir ve bu bilgilere göre de karar verebilir. Yapay sinir ağları ise yapay zekâlarda makine öğrenimi için en çok bilinen ve kullanılan yöntemdir. Bu yöntem geleneksel hesaplama yöntemleri ile çözülemeyen sorunların çözümlenmesinde çokça kullanılmaktadır. Yapay sinir ağları, insan beyninin özellikleri arasında yer alan; öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacıyla geliştirilen bilgisayar sistemleridir (Çırak ve Çokluk, 2013).

Eğitim alanında da yapay sinir ağları kullanımı hızla artmakta ve bu alanda kullanımı önemsenmeye başlamıştır. Yine gelişen teknoloji ile okullarda ve eğitim kurumlarında bilgi sistemlerinde her türlü veriye ulaşım sağlanmaktadır. Ulaşımı sağlanan bu verileri diğer hesaplama yöntemleriyle işleme imkânı olmayan analiz veya tahminler ise yapay sinir ağları ile hesaplanabilmektedir. İstatistiksel tahmin için birçok yöntem vardır. Araştırmacılar öğrenci başarıları ya da başarısızlıklarının tahmininde lojistik regresyon, stepwise lineer regresyon, diskriminant analizi ve yapay sinir ağlarını karşılaştıran çalışmalar yapmış; çoğu araştırmada YSA'nın

tahmin başarısının diğere metotlardan daha iyi seviyede olduğunu vurgulamışlardır (Gorr, Nagin ve Szczypula, 1994; Flitman, 1997; İbrahim ve Rusli, 2007; Tosun, 2007; Tepehan, 2011). Eğitim alanında yapay sinir ağları ile az sayıda çalışma olmasına rağmen Öğrenme, genelleme, doğrusal olmama, hata toleransı, uyum, paralellik gibi üstünlüklere sahip olan yapay sinir ağları; mühendislik alanında üretim, finans, optimizasyon, sınıflandırma, tıbbi uygulamalarda ise görüntü ve sinyal işleme, hastalık tahmini gibi çalışma alanlarında kullanılmaktadır.

Bir öğrencinin akademik başarısını tahmin etmede bize en çok yol gösteren etmenler öğrencinin akademik geçmişidir. Ankara Üniversitesi'nde yapılan bir çalışma da Ankara Üniversitesi'nde farklı bölümlerde okuyan 419 üçüncü sınıf öğrencilerinin akademik başarılarını etkileyen faktörleri kullanarak öğrencilerin başarı durumlarına göre sınıflandırılmasında Yapay Sinir Ağları ve Lojistik regresyon yöntemleri kullanılmıştır. "Ortaöğretim Mezuniyet Ortalaması, Mezun Olunan Lise ve Üniversiteye Giriş Puanı" ortak değişkenler olarak belirlenen çalışmada lojistik regresyon analizi ve yapay sinir ağları analizi ile öğrencilerin akademik başarısını en çok hangi değişkenlerin etkilediğine ilişkin karşılaştırma yapılmıştır. Çalışma sonunda yapay sinir ağları analizi sonucu akademik başarının ilk belirleyicisi yüzde yüz oranla "Üniversiteye Giriş Puanı" olduğu anlaşılmıştır (Çırak 2012).

Eğitimde öğrencinin başarısızlığını önlemek için öncelikle başarıyı etkileyen sebeplerin anlaşılması gerekir. Bundan dolayı başarıyı etkileyen durumlar belirlenerek başarısızlığa sebep olan durumlar kontrol edilebilir ve öğrencilerin niteliklerine göre daha doğru bir sınıflandırma yapılabilir.

İnsan yetiştirmenin çok önemli olduğu bu zamanda eğitim kurumlarında öğrencilerin derslerde gösterdikleri performans da önemli hale gelmektedir. Daha sonra ne olacağını belirlemek için öğrencinin geçmiş verilerini ve mevcut verilerini kullanarak oluşturulacak tahmin modeli uygulamaları ile öğrencilere rehberlik çalışmaları yapılabilmesine imkân tanınacaktır. Öğrencilerin derslerde gösterecekleri performansı arttırmak, sene başından hangi derse daha fazla ağırlık vermeleri gerektiğini görmeleri ve gerçekçi hedefler koyabilmelerini sağlamak veya düşük performans gösterecek öğrencilerin belirlenerek bu öğrencilerin harekete geçmesini ve tüm potansiyellerine ulaşmalarına yardımcı olacak yöntemlerin uygulanması sağlanacaktır.

Araştırmanın Amacı

Fen Bilimleri Dersi Öğretim Programında, farklı sınıf düzeylerinde ve temalarda sarmal bir yaklaşımla tekrar eden kazanımlara ve açıklamalara aynı zamanda bütünsel ve bir kerede kazandırılması hedeflenen öğrenme çıktıklarına yer verilmektedir. Bu çalışmada; ilkokul 4. sınıftan itibaren öğrencilerin Fen Bilimleri derslerindeki başarılarının, bir üst sınıf seviyesindeki başarılarıyla da ilişkilendirmek suretiyle liselere giriş sınavındaki Fen Bilimleri dersi başarısının yapay sinir ağları ile yordanması amaçlanmaktadır.

Araştırmanın Önemi

Öğrencinin başarısının yordanmasına yönelik çalışmalarda pek çok faktörün etkili olduğu görülmektedir. Özellikle liseye geçişte kullanılan (OKS, SBS, TEOG gibi) sınav başarılarının yordanmasında bağımsız değişken olarak yazılı sınav notlarının işe koşulduğu görülmektedir. Bu çalışmada da öğrencilerin ilkokuldan itibaren 5.6.7.8 sınıf ve LGS Fen Bilimleri dersi başarılarının yordanmasında ilkokul ders başarılarının işe koşulması önemli bir fark yaratmaktadır. Yapılacak çalışmadan elden edilen bulgular 2005 yılından itibaren uygulamaya konulan tüm Fen Bilimleri dersi öğretim programlarında sarmal olarak düzenlenen içeriğin kademeli olarak üst sınıf seviyelerine katkı sağlayıp sağlamadığı ile ilgili ışık tutacaktır.

Ayrıca araştırmanın bir diğer katkısı kullanılan metodolojidir. Yapay sinir ağları için çeşitli programlama dillerinde birçok araç ve kütüphane geliştirilmiştir. Matlab Neural Network Toolbox, yapay sinir ağlarının tasarlanmasını, gerçekleştirilmesini, görselleştirilmesini ve benzetimini sağlayan, Matlab için geliştirilmiş bir araçtır. Özellikle eğitim alanında yapılan birçok araştırma sayısal hesaplama programları içerisinde yer alan hazır yapay sinir ağları araçları kullanılarak oluşturulmuştur. Bu çalışmada ise; öğrenci akademik başarısının yordanmasına yönelik yapılan çalışmalar, metodoloji bağlamında ele alındığında araştırmada kullanılan Matlab 2018a programının editör kısmında yazılan kod satırlarıyla oluşturulan yazılımın, özgünlük açısından literatüre önemli katkı sağlayacağı düşünülmektedir.

Problem Cümlesi

Bu çalışma kapsamında “Öğrencilerin ilkokuldan itibaren 4., 5., 6., 7. ve 8. sınıf Fen Bilimleri dersi başarıları ile liselere geçiş sınavında Fen Bilimleri dersi alt testindeki başarılarını tahmin etme düzeyi nedir?” sorusuna cevap aranmaktadır. Bu doğrultuda araştırmanın alt problemleri şunlardır;

Alt Problem 1: Öğrencilerin ilkokuldan itibaren 4., 5., 6., 7. ve 8. sınıf Fen Bilimleri dersi yazılı sınav başarıları ile LGS sınavı fen bilimleri alt testi başarıları arasındaki ilişki düzeyi nedir?

Alt Problem 2: Öğrencilerin ilkokuldan itibaren (4., 5., 6., 7. ve 8. sınıf) fen bilimleri ders başarıları, LGS sınavı fen bilimleri alt testindeki doğru sayılarını YSA ile ne derecede tahmin etmektedir?

Varsayımlar (Sayıtlar)

Fen Bilimleri/Fen ve Teknoloji dersi yazılı sınav notlarının öğrencilerin fen dersi başarılarını yansıttıkları varsayılmaktadır.

Farklı okullarda farklı öğretmenler tarafından yapılan fen dersi yazılı sınavlarının eşdeğer olduğu ve farklı ortamlarda yapılan sınavların öğrenci başarısına etkisinin değişmediği kabul edilmiştir.

Araştırmanın Sınırlılıkları

Bu çalışmada bulunan sınırlılıklar aşağıdaki gibi sıralanabilir:

- Araştırmada öğrencilerin Fen Bilimleri dersi başarıları 2013-2014, 2014-2015, 2015-2016, 2016-2017, 2017-2018 eğitim-öğretim yıllarında Fen Bilimleri/Fen ve Teknoloji dersi yazılı sınav notlarıyla sınırlıdır.
- Araştırmada öğrencilerin LGS sınavı Fen Bilimleri alt testi başarıları, 2018 LGS sınavı sonuç belgesinde yer alan Fen Bilimleri alt testinde yapılan doğru sayıları ile sınırlıdır.
- Bu araştırma, Bursa ilinde 2017-2018 eğitim-öğretim yılında LGS sınavına girmiş aynı zamanda ilkokul 4. Sınıftan itibaren 8. Sınıfa kadar okul sistemi raporlar bölümünden geçmiş yıllara ait not çizelgelerine ulaşılabilen öğrencilerle sınırlıdır.

- Yapay sinir ađları ile yapılan analiz alıřmaları MATLAB 2018a programında oluřturulan algoritmalar ile sınırlıdır.

İlgili alıřmalar

Yapılan literatür taraması sonucunda bu arařtırma için odaklanılmak istenen konu, akademik başarının yapay sinir ađları ile tahmin edilmesinde ađın tahmin performansının literatürdeki alıřmalarla desteklenerek karşılaştırılmasıdır. Bu nedenle ilgili alıřmalar bölümünde sadece fen bilimleri alanına yönelik yapılan alıřmalar deđil akademik başarının yordanması konusunda önemli görölen arařtırmalar kronolojik olarak sıralanmıř ve ařađıda kısaca deđinilmiřtir.

1994 yılında Gorr, Nagin ve Szczypula'nın öđrencilerin ađrılıklı not ortalamalarının tahmininde oklu dođrusal regresyon ve ařamalı dođrusal regresyon analizleri ile yapay sinir ađları analizlerini karşılaştırması ile gerekleřtirilmiřtir. Arařtırma bulgularına göre yapay sinir ađları analizi ile yapılan tahminlerin daha iyi olduđu sonucuna varılmıřtır. Ayrıca, basit yapay sinir ađları için model yapısının optimizasyonu da dahil olmak üzere yapay sinir ađlarının uygulanması, yorumlanması ve deđerlendirilmesi için yöntemler sunmuřlardır (Subbanarasimha, Arinzeb,& Anandarajanb (2000); Akt: ırak, 2012).

1997 yılında Sittirug alıřmasında ilköđretim öđretmen adaylarının fen başarısının regresyon analizi ile yordanmasında fene yönelik tutum, bilimsel süreç becerileri ve biliřsel gelişim düzeylerini iře kořmuřtur. 80 ilköđretim öđretmen adayı üzerinde gerekleřtirdiđi alıřmada fen başarısının kestirilmesinde en önemli yordayıcının bilimsel süreç becerileri olduđu sonucuna ulařmıřtır.

2000 yılında Hunt tarafından yapılan doktora tez alıřmasında birinci sınıf öđrencilerinin akademik başarılarının yordanmasında yapay sinir ađları ile lojistik regresyon analizinin performansları karşılařtırmıřtır. Arařtırma sonucu hem lojistik regresyon analizinin hem de geri beslemeli yapay sinir ađları metodunun kabul edilebilir düzeyde dođru yordamalar yaptıđı sonucuna ulařmıřtır.

2004 yılında Güneri ve Apaydın, öđrencileri başarı durumlarına göre sınıflandırmada yapay sinir ađları ve lojistik regresyon yöntemlerini kullanmıřlardır. Gazi Üniversitesi Ticaret ve Turizm Eđitim Fakóltesi'nde kayıtlı bütün öđrencilerden seilen arařtırma grubuyla yürütölen alıřmada öđrencilerin

cinsiyetleri, lise ortalamaları, mezun olduğu lise türü, ÖSS puanları, ailenin yaşadığı şehir ve yaş kriterleriyle yapılan sınıflamada öğrencilerin bölümde yer alan programlardan hangisine daha uygun olduğuna ilişkin bir çalışma yapılmıştır. Başarı sınıflandırmasında lojistik regresyon analizi ve sinir ağları yaklaşımı sonucunda elde edilen genel doğru sınıflandırma oranı %97 olarak bulunmuştur.

2007 yılında Tosun, yaptığı çalışmada yapay sinir ağları ve karar ağaçları tekniklerini karşılaştırarak üniversite öğrencilerinin başarılarını etkileyen faktörlerin gözlemlenmesini amaçlamıştır. Karar ağaçları ile öğrenci başarılarına göre sınıflandırma işlemi sonrasında %86 oranında başarı elde edilmiştir. Aynı verilerle yapılan yapay sinir ağları uygulaması sonrasında başarı oranı yaklaşık %91,77 olarak ortaya koymuştur. Çalışmada öğrencilerin derse devam yüzdesi, sınıfı, çalışma saati, babasının hayatta olup olmaması, kaldığı yer, babasının eğitim durumu gibi değişkenler başarı üzerinde etkili olarak gözlemlenmiştir.

2007 yılında Ayık, Özdemir ve Yavuz yaptıkları çalışmada 1976-2007 yılları arasında Atatürk Üniversitesi'nden mezun olmuş veya hâlâ okumakta olan öğrencilerin lise türü ve lise mezuniyet başarılarının okudukları veya mezun oldukları fakülte ile ilişkisinin tespit edilmesi amaçlanmıştır. Farklı veri madenciliği metodlarının kullanıldığı çalışmada yaklaşık 50.000 kayıt, veri madenciliğinin veriyi hazırlama süreçlerinden geçirilerek veri tabanından bilgi keşfi süreci anlamlı hâle getirilmiştir. Araştırma sonucunda, lise türünün ve lise başarısının kazanılan fakülte ile önemli derecede ilişkili olduğu sonucuna ulaşılmıştır.

2008 yılında Oladokun, Adebajo ve Charles-Owaba, yaptıkları çalışmada son zamanlarda bazı Nijeryalı üniversitelerden mezun olan öğrencilerde gözlemledikleri kalitesizliğe, kısmen Ulusal Üniversite Kabul Sınavı Sisteminin yetersizliklerine odaklanarak öğrenci başarısı üzerinde etkili olan değişkenleri belirlemek ve öğrenci performansını tahmin etmede yapay sinir ağları analizini test etmeyi amaçlamışlardır. YSA modelinde, sıradan düzeydeki deneklerin puanları ve öznelerin kombinasyonu, giriş sınavı puanları, kabul yaşı, ebeveyn arka planı, katılan orta öğretim okulu ve cinsiyet gibi unsurlar girdi değişkenleri olarak kullanılmıştır. Modele eklenecek yeni bir öğrencinin gelecekteki başarısı tahmin edilmek istendiğinde, yapay sinir ağları kullanıldığı zaman tahminin doğru olma olasılığı %74 olarak belirlenmiştir.

2011 yılında Tepehan çalışmasında öğrenci başarısının yordanması amacıyla oluşturduğu YSA' nın (Çok Katmanlı Algılayıcı Modeli) performansı ile aynı amaçla oluşturduğu lojistik regresyon (LR) modelinin performansı, doğru sınıflandırma oranlarından faydalanılarak karşılaştırmıştır. Karşılaştırmada PISA-2003'e katılan 4855, PISA-2006'ya katılan 4942 ve PISA-2009'a katılan 4996 Türk öğrencinin test ve anket sonuçlarından yararlanılmıştır. YSA, başarısız öğrencilerin %76,3'ünü doğru sınıflandırırken, LR modeli başarısız öğrencilerin %72,5'ini doğru sınıflandırmıştır. Bu kapsamda; okuma başarısı açısından YSA, hem genel sınıflandırmada ve hem de başarısız öğrencilerin sınıflandırılmasında, LR modeline göre kısmen daha iyi sonuçlar verdiğini söylemek mümkündür. Bu nedenle öğrenci başarısını etkileyen faktörlerin belirlenmesi ve öğrenci başarısının yordanması çalışmalarında YSA'nın güvenilir bir şekilde kullanılabilmesi düşünülmüştür.

2012 yılında Çırak, çalışmasında, öğrenci başarısını etkileyen değişkenlerin belirlenmesi ve başarının tahmin edilmesi için lojistik regresyon ve yapay sinir ağlarını metotlarının performansını incelemeyi amaçlamıştır. Araştırmanın çalışma grubunu Ankara Üniversitesi Eğitim Bilimleri Fakültesi ile Dil ve Tarih-Coğrafya Fakültesi'ndeki lisans programlarına kayıtlı 419 üçüncü sınıf öğrencisi oluşturmaktadır. Araştırma sonuçlarına bakıldığında, yapay sinir ağlarının %70,16 ile; lojistik regresyon analizinin ise %66,10 daha iyi performans gösterdiği görülmüştür. Yapay sinir ağlarını daha doğru sınıflandırma yaptığı sonucuna ulaşılmıştır. Ayrıca bu iki analiz metodunun karşılaştırmasında ortaöğretim mezuniyet ortalaması, mezun olunan lise ve üniversiteye giriş puanı akademik başarıya etki eden ortak değişkenler olarak bulunmuştur. Yapay sinir ağlarında üniversiteye giriş puanı, lojistik regresyonda ise mezun olunan lise başarıyı en çok etkileyen değişken olmuştur.

2013 yılında Musso, Kyndt, Cascallar ve Dochy çalışmalarında, YSA kullanarak öğrenci performansının tahmini modellerini tasarlamak için öğrencilerin bilişsel ve bilişsel olmayan ölçütlerini arka plan bilgisi olarak kullanmıştır. Bu performans tahminleri, gözlemlenen akademik performans ölçüsünden bir yıl öncesine göre akademik performansın gerçek bir tahmini sınıflandırmasını oluşturmuştur. Her iki cinsiyetten 18 ve 25 yaşları arasında değişen 864 üniversite öğrencisi kullanılmıştır. Üç sinir ağı modeli geliştirildi. Modellerin ikisi (sırasıyla en üst %33 ve en düşük %33 grupları tanımlayanlar), her iki gruptaki tüm

öğrencilerin %100 doğru tanımlamasına ulaşabildi. Üçüncü model (düşük, orta ve yüksek performans seviyelerini tanımlayan), üç grup için %87'den %100'e kadar kesinliğe ulaştı. Sonuçlar, geleneksel yöntemlerle karşılaştırıldığında YSA' nın daha fazla doğruluğunu ortaya koymuştur.

2014 yılında Özdemir araştırmasında; 2013 yılında YGS' ye giren öğrencilerin bu sınavdaki alt testlerle ilgili 7-12 sınıf yıl sonu başarı puanlarının YGS alt testi ham puanlarını yordama gücüne bakmıştır. Çalışma 2013 yılında Ankara ilinde YGS' ye giren 533 öğrenci ile yapılmıştır. Araştırmada aynı öğrenciye ait ilköğretim ve ortaöğretim yıl sonu başarı puanları kullanılmıştır. Bu çalışmada adımsal çoklu regresyon yöntemi kullanılmıştır. Araştırmada elde edilen bulgulara göre, YGS Türkçe alt testini en iyi yordayan değişkenlerin 11. sınıf dil ve anlatım, 8. sınıf Türkçe, 12. sınıf dil ve anlatım, 7. sınıf Türkçe ve 12. sınıf edebiyat yıl sonu başarı puanları olduğu ve bu değişkenlerin YGS Türkçe alt testindeki başarının %58'ini açıkladığı görülmektedir. YGS Matematik alt testini en iyi yordayan değişkenlerin 12. sınıf matematik, 8. sınıf matematik, 12. sınıf geometri, 10. sınıf matematik ve 7. sınıf matematik yıl sonu başarı puanları olduğu ve bu değişkenlerin YGS matematik alt testindeki başarının %71'ini açıkladığı görülmektedir. YGS Fen bilimleri alt testini en iyi yordayan değişkenlerin 12. sınıf seçmeli kimya, 11. sınıf seçmeli kimya, 12. sınıf seçmeli biyoloji ve 11. sınıf seçmeli fizik yıl sonu başarı puanları olduğu ve bu değişkenlerin YGS Fen bilimleri alt testindeki başarının %50'sini açıkladığı görülmektedir. YGS Sosyal bilimler alt testini en iyi yordayan değişkenlerin 12. sınıf seçmeli coğrafya, 11. sınıf T.C. inkılap tarihi ve Atatürkçülük ve 10. sınıf coğrafya yıl sonu başarı puanları olduğu ve bu değişkenlerin YGS Sosyal Bilimler alt testindeki başarının %50'sini açıkladığı görülmektedir.

2015 yılında Özdemir çalışmasında öğretmenlerin gelişmesinde, işe motive olmasında ve eğitimdeki kalitede rol oynayan mesleki tükenmişliği etkileyen değişkenler yapay sinir ağı ile öngörülmüş, incelenmiş ve bu değişkenler arasındaki ilişkiler ortaya çıkarmayı amaçlamıştır. Nicel verilere parametrik testlerden bağımsız gruplarda t-testi, tek faktörlü varyans analizi (ANOVA), basit korelasyon ve çoklu doğrusal regresyon uygulanmıştır. Öz-yeterlik, yetkinlik değişkenlerinin ve mesleki tükenmişliğin alt boyutlarının mesleki tükenmişliği açıklama derecesini bulmak ve araştırmanın konusuyla ilgili kestirimler yapabilmek için araştırmadan

elde edilen verilere YSA uygulanmıştır. Bunun için MATLAB paket programı kullanılmıştır. Yapay sinir ağı ile “duygusal tükenme”, “kişisel başarı”, “duyarsızlaşma” ve “yetkinlik” faktörlerinin kestirimi olmak üzere dört kestirim çalışması yapılmıştır ve yapay sinir ağının girdilerine karşılık ürettiği bazı kestirimler, kabul edilir hata oranıyla, gerçek çıktı değerlerine yaklaşmıştır. Yapay sinir ağı ile regresyon analizi sonuçları karşılaştırıldığında; “duygusal tükenme” için ağın performansının yaklaşık %40 ve regresyon performansının yaklaşık %30; “duyarsızlaşma” için ağın performansının yaklaşık %20 ve regresyon performansının yaklaşık %38; “kişisel başarı” için ağın performansının yaklaşık %50 ve regresyon performansının yaklaşık %29; “yetkinlik” için ağın performansının yaklaşık %80 ve regresyon performansının yaklaşık %58 olduğu görülür. Çalışmanın sonucuna göre mesleki tükenmişliği etkileyen değişkenleri belirlemek ve mesleki tükenmişliği kestirebilmek için YSA güvenli bir şekilde kullanılabilceği sonucuna ulaşılmıştır. Bu bağlamda eğitim alanındaki araştırma verilerinin çözümlenmesine yeni bir bakış açısı kazandırılmıştır.

2017 yılında Aydoğan çalışmasında, öğrencilerin dönem sonunda ulaşacakları başarı ölçülerinin dönem içerisinde kestirilmesi ve kestirilen bu ölçülerle ortaya çıkan başarı durumları referans alınarak, başarılarını etkileyen örgütsel unsurların neler olabileceğinin dönem içerisinde belirlenmesini amaçlamıştır. Araştırma verileri Yüzüncü Yıl Üniversitesi 2015 – 2016 Öğretim Yılı Güz Dönemi ve bu dönemde öğrenim gören 2. ve 3. sınıf öğrencilerini kapsamaktadır. Araştırma, 1049 öğrenci üzerinden yürütülmüştür. Çalışmada, 17'si girdi, 1'i çıktı olmak üzere 18 değişkenin yer aldığı YSA yöntemiyle geliştirilen bir tahmin modeli ve 1'i yordanan (bağımlı), 23'ü yordayıcı (bağımsız) olmak üzere 24 değişkenin yer aldığı LRA (Lojistik Regresyon Analizi) yöntemiyle geliştirilen iki etki modeli yer almıştır. YSA ile tahmin modelinin geliştirilmesi 3. sınıf öğrenci verileri kullanılarak gerçekleştirilmiştir, tahmin ve etki modellerinde 2. sınıf öğrenci verileri kullanılmıştır. Elde edilen sonuçlara göre, kestirilen (tahmin edilen) başarı ölçüleri ile gözlenen başarı ölçülerinin ve bu ölçülerle oluşan başarılı/başarısız şeklindeki başarı durumlarının önemli ölçüde benzerlik gösterdiği görülmüştür.

2017 yılında Akgün çalışmasında, 2014 ve 2015 yıllarında sınıf eğitimi bölümünden mezun olan öğretmen adaylarının fen ve teknoloji öğretimi I ve II derslerindeki akademik başarılarını yordamayı amaçlamıştır. Bu amaç

doğrultusunda yordama için yapay sinir ağıları kullanılmıştır. Araştırma çerçevesinde elde edilen veriler, 4 farklı devlet üniversitesinden 2013-2014 ve 2014-2015 eğitim-öğretim yıllarında mezun olmuş 885 sınıf öğretmeni adaylarının transkript dökümleri ve öğrenci bilgi sistemlerinde bulunan kişisel bilgi içermeyen demografik bilgilerinden elde edilmiştir. Araştırma kapsamında oluşturulan ağ mimarisinin OKH= 0.47754; Öğrenme R= 0.81632, Doğrulama R= 0.90097 ve Test R=0.87808 değerleri bulunmuştur. 200 kişinin girdi verileri kullanılarak ağın öğrenme sürecinin ardından simüle edilen başarı notlarındaki hata değerinin büyük bir çoğunluğunun Fen ve Teknoloji Öğretimi I Dersi için (N=164), Fen ve Teknoloji Öğretimi II Dersi için (N=177); [-1, 1] aralığında olduğu sonucuna ulaşılmıştır. Bununla birlikte gerçek başarı notları ile tahmin edilen başarı notları istatistiksel olarak karşılaştırıldığında; Fen ve Teknoloji Öğretimi I Dersinde $r=.6935$ ($p<0.001$), Fen ve Teknoloji Öğretimi II Dersinde $r=.6748$ ($p<0.001$) ilişkinin olduğu sonucuna ulaşılmıştır. Fen ve Teknoloji Öğretimi I ve II Derslerinin ikisi içinde önem derecesi en yüksek değişkenin Yerleşme Puanı olduğu, önem derecesi en düşük değişkenin ise Fen ve Teknoloji Öğretimi I dersi için öğrenim türü, Fen ve Teknoloji Öğretimi II dersi için ise cinsiyet olduğu görülmüştür.

İkinci Bölüm

Yöntem

Araştırmanın Modeli

Bu çalışmanın amacını, 2017-2018 eğitim-öğretim yılında 8.sınıftan mezun olan ortaokul öğrencilerinin Fen Bilimleri dersindeki akademik başarılarını yordamak oluşturmaktadır. Bu çalışma da öğrencilerin LGS (Liselere Geçiş Sınavı) Fen Bilimleri dersinden yaptıkları doğru sayıları ile ilgili derse ait ilkökul ve ortaokul sınav notlarının arasındaki ilişkilere bakılmıştır. Bu araştırma iki ya da daha fazla değişken arasındaki birlikte değişim varlığını ve derecesini belirlemeye çalışan ilişkisel türden betimsel bir çalışma niteliğindedir.

Çalışma Grubu

Araştırmanın çalışma grubunu Bursa ilinin 17 ilçesindeki 24 ortaokuldan 2017 – 2018 eğitim-öğretim yılında 8.sınıfta LGS' ye giren öğrenciler oluşturmaktadır. Okullar belirlenirken Bursa ilindeki ilçelerin nüfus yoğunlukları ve okulların buldukları ilçedeki en kalabalık öğrenci mevcudu durumu göz önüne alınmıştır. Ayrıca farklı okul türleri de göz önünde bulundurularak ortaokul, imam-hatip ortaokulu ve yatılı bölge ortaokulları belirlenmiştir. 17 ilçenin nüfus yoğunluklarına bakıldığında en kalabalık olan 3 ilçesinden (Osmangazi, Nilüfer ve Yıldırım) 3'er ortaokul, merkez ilçe olmayan ancak nüfus yoğunluğu bakımından oldukça kalabalık olan 1 ilçesinden (İnegöl) 2 ortaokul ve diğer ilçelerden 1'er ortaokul belirlenmiştir. 2012-2013 eğitim-öğretim yılından itibaren eğitim sisteminde yapılan değişiklik ile (4+4+4) ilkökul ve ortaokul binaları ayrılmıştır. Dolayısıyla 2018 yılında mezun olan öğrencilerin 2013 – 2014 eğitim-öğretim yılındaki 4. sınıf verilerine ulaşmak için belirlenecek ilkökullar, adrese dayalı kayıt sistemine göre ortaokula en yakın bulunan ilkökullar taranarak tespit edilmiştir.

Verilerin Toplanması

2018 yılında ortaokuldan mezun olmuş öğrencilerin LGS sonuç belgeleri ve geçmiş döneme ait (4., 5., 6., 7. ve 8. Sınıf) not fişleri e-okul sistemi raporlar bölümünde yer alan geçmiş dönemlere ait not çizelgeleri .xls uzantılı Excel dosyası formatında alınmıştır.

Toplamda 5135 ortaokul 8. sınıf öğrencisinin verileri toplanmış ancak 4., 5., 6., 7. ve 8. sınıfın tamamını aynı okulda okumayan öğrencilerin, not fişlerinde verileri gözükmemesinden dolayı gerekli tüm verilerine ulaşılamamış ve eksik verisi olan öğrencilere ait satırlar ayıklanmıştır. Aynı zamanda 2018 yılı LGS sınavı tüm öğrencilere mecburi tutulmadığı içinde bir kısım öğrenci verisinin silinmesi gerekmiştir. Bundan dolayı öğrencilerin sınav notları Microsoft Excel programında veri temizleme çalışması yapılarak düzenlenmiş, 1027 öğrencinin ayıklanmış verisi çalışmada kullanılmak üzere hazır hale getirilmiştir.

Verilerin Düzenlenmesi

Verilerin toplanmasına belirlenen 24 ortaokuldaki öğrencilerin 2018 LGS sınav sonuç belgelerinden başlanmıştır. Sınav sonuç belgesinde yer alan altı dersten yapılan doğru, yanlış, boş sayıları ve merkezi sınav puanları ayrı bir Excel sayfasında oluşturulan formüller aracılığıyla listelenmiştir. Yapılan bu çalışma ile ilgili örnek Şekil 10'da gösterilmektedir.

J	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	
1		TÜRKÇE			MATEMATİK			FEN BİLİMLERİ			TARİH			DİN			YABANCI DİL			Puan	
2		D	Y	B	D	Y	B	D	Y	B	D	Y	B	D	Y	B	D	Y	B		
3		15	5	0	6	7	7	8	10	2	8	2	0	9	1	0	4	4	4	2	251.4996
4		14	6	0	4	11	5	12	3	5	9	1	0	10	0	0	4	6	0	255.0594	
5		16	4	0	5	5	10	14	3	3	10	0	0	10	0	0	9	1	0	313.5484	
6		14	6	0	6	10	4	14	4	2	9	1	0	7	3	0	0	2	8	268.7376	
7		16	4	0	7	8	5	15	5	0	10	0	0	9	1	0	8	2	0	317.564	
8		15	5	0	12	5	3	15	5	0	10	0	0	10	0	0	5	5	0	353.4248	
9		12	8	0	5	13	2	12	7	1	8	2	0	8	2	0	1	9	0	227.6709	
10		15	2	3	3	7	10	7	7	6	9	1	0	10	0	0	5	3	2	240.8171	
11		13	6	1	1	15	4	6	12	2	7	3	0	10	0	0	3	6	1	197.8309	
12		15	3	2	4	9	7	8	6	6	5	3	2	9	0	1	2	2	6	232.1962	
13		7	13	0	6	14	0	6	14	0	3	7	0	8	2	0	3	7	0	151.6099	
14		18	2	0	8	8	4	12	2	6	10	0	0	10	0	0	4	6	0	320.6867	
15		14	5	1	3	9	8	13	5	2	2	2	6	8	1	1	2	2	6	234.7727	
16		11	9	0	9	5	6	13	7	0	7	3	0	8	2	0	8	2	0	287.8177	
17		13	6	1	4	16	0	7	8	5	9	1	0	9	1	0	0	0	10	209.7169	
18		12	8	0	8	12	0	5	15	0	7	3	0	9	1	0	2	8	0	206.8701	
19		15	5	0	9	8	3	14	6	0	9	1	0	10	0	0	10	0	0	325.5361	
20		9	10	1	1	9	10	5	8	7	8	2	0	6	4	0	1	2	7	165.2011	
21		10	10	0	6	14	0	6	14	0	6	4	0	7	3	0	3	7	0	174.084	
22		19	1	0	6	9	5	13	7	0	9	1	0	10	0	0	10	0	0	316.8742	
23		18	2	0	1	8	11	7	11	2	9	1	0	10	0	0	7	3	0	245.8789	
24		16	4	0	4	11	5	6	12	2	10	0	0	8	2	0	9	1	0	231.9955	
25		16	4	0	4	3	13	12	4	4	9	1	0	10	0	0	2	2	6	284.2448	
26		9	6	5	2	16	2	5	12	3	6	2	2	3	4	3	1	8	1	154.5488	
27		10	10	0	4	8	8	6	11	3	6	4	0	7	2	1	3	4	3	181.3693	
28		15	5	0	2	6	12	9	5	6	7	3	0	10	0	0	7	3	0	242.4101	
29		18	2	0	3	10	7	12	7	1	9	1	0	10	0	0	5	5	0	271.644	
30		17	3	0	3	8	9	11	8	1	10	0	0	10	0	0	8	2	0	271.6601	
31		11	6	3	0	3	17	4	3	13	7	1	2	9	0	1	2	0	8	194.8645	
32		12	8	0	2	4	14	14	5	1	9	1	0	10	0	0	6	2	2	258.2752	
33		10	10	0	4	10	6	5	15	0	5	5	0	8	2	0	3	6	1	163.3964	
34		14	4	2	2	2	16	12	8	0	10	0	0	10	0	0	8	2	0	269.6055	
35		17	2	1	5	6	9	14	4	2	10	0	0	10	0	0	7	3	0	311.9631	
36		14	6	0	1	15	4	3	16	1	8	2	0	9	1	0	5	5	0	196.4377	
37		11	3	6	3	7	10	4	4	12	0	0	10	4	1	5	0	0	10	174.4128	
38		20	0	0	12	3	5	17	3	0	10	0	0	10	0	0	10	0	0	412.0502	
39		13	7	0	1	4	15	12	4	4	7	3	0	10	0	0	5	1	4	244.4961	
40		11	8	1	2	14	4	8	12	0	6	4	0	6	4	0	2	4	4	181.0957	
41		9	10	1	4	13	3	5	13	2	7	3	0	9	1	0	3	6	1	165.3446	
42		9	10	1	1	7	12	11	8	1	10	0	0	8	2	0	2	4	4	206.6969	
43		17	3	0	5	6	9	14	6	0	9	1	0	10	0	0	10	0	0	311.6862	

Şekil 10. LGS' ye giren öğrencilerin düzenlenen sınav sonuç bilgileri.

Sonra öğrencilerin geçmiş dönemlere ait not çizelgelerinden Fen Bilimleri dersine ait yazılı sınav notları, Şekil 11'de gösterilen Excel içerisinde bulunan visual basic uygulaması aracılığıyla 5., 6., 7., ve 8. sınıf düzeyine göre oluşturulmuş ve ilgili sütunlara aktarılmıştır. Bu program aynı zamanda LGS sınavına giren

öğrenci ismine göre tarama yaparak sadece sınav sonuç belgesi olan öğrenci ismine göre alfabetik sıralama yapmıştır. Yeni oluşturulan Excel sayfasında sınava girmeyen öğrenciler ve 5., 6., 7., ve 8. sınıf düzeylerinden herhangi birisinde ulaşılabilen veriler, Şekil 12 de görüldüğü gibi “#YOK” olarak gösterilmiştir.

```

Sub EOkuldanSubeOgrenciDersCizelgesi(Kitap As Workbook, sayfAdi As String, yeniKitap As Workbook, yeniSayfaAdi As String)
Dim dersler8(6)
dersler = Array("TÜRKÇE", "MATEMATİK", "TARİH/SOSYAL", "İNGİLİZCE", "DİN", "FEN")
Dim sayfam1
Dim sayfam2
Set sayfam1 = kitap.Worksheets(sayfaAdi)
Set sayfam2 = KitapSayfaSec(yeniKitap, yeniSayfaAdi)

'Bağlıklar yazılıyor
For h = 0 To 5
sayfam2.Cells(2, 2 + h * 6) = dersler(h)
Next h

i = 0
dersno = 1
While (sayfam1.Cells(i + 4, 1) <> "")
i = i + 1
siraNo = sayfam1.Cells(3 + i, 1)
If (eskiSiraNo > sirano) Then
dersno = dersno + 1
End If

```

Şekil 11. Excel programında yazılan makronun ekran görüntüsü

Öğrenci No	5	6	7	8
25	62	73	65	51
26	62	73	65	51
27	62	73	65	51
28	62	73	65	51
29	62	73	65	51
30	62	73	65	51
31	62	73	65	51
32	62	73	65	51
33	62	73	65	51
34	62	73	65	51
35	62	73	65	51
36	62	73	65	51
37	62	73	65	51
38	62	73	65	51
39	62	73	65	51
40	62	73	65	51
41	62	73	65	51
42	62	73	65	51
43	62	73	65	51
44	62	73	65	51
45	62	73	65	51
46	62	73	65	51
47	62	73	65	51
48	62	73	65	51
49	62	73	65	51
50	62	73	65	51
51	62	73	65	51
52	62	73	65	51
53	62	73	65	51
54	62	73	65	51
55	62	73	65	51
56	62	73	65	51
57	62	73	65	51
58	62	73	65	51
59	62	73	65	51
60	62	73	65	51
61	62	73	65	51
62	62	73	65	51
63	62	73	65	51
64	62	73	65	51
65	62	73	65	51
66	62	73	65	51
67	62	73	65	51
68	62	73	65	51
69	62	73	65	51
70	62	73	65	51
71	62	73	65	51
72	62	73	65	51
73	62	73	65	51
74	62	73	65	51
75	62	73	65	51
76	62	73	65	51
77	62	73	65	51
78	62	73	65	51
79	62	73	65	51
80	62	73	65	51

Şekil 12. Öğrencilerin Fen Bilimleri dersine ait yazılı sınav puan bilgileri.

Daha sonra verilerinin tamamına ulaşılabilen öğrenciler Excel programının “Bul ve Değiştir” aracıyla belirlenerek silinmiştir. Bu şekilde başlangıçta ulaşılan 5135 ortaokul öğrenci verisinden 3187 öğrencinin 5., 6., 7., ve 8. Sınıf düzeyine ait verileri kalmıştır. 2012-2013 eğitim-öğretim yılından itibaren

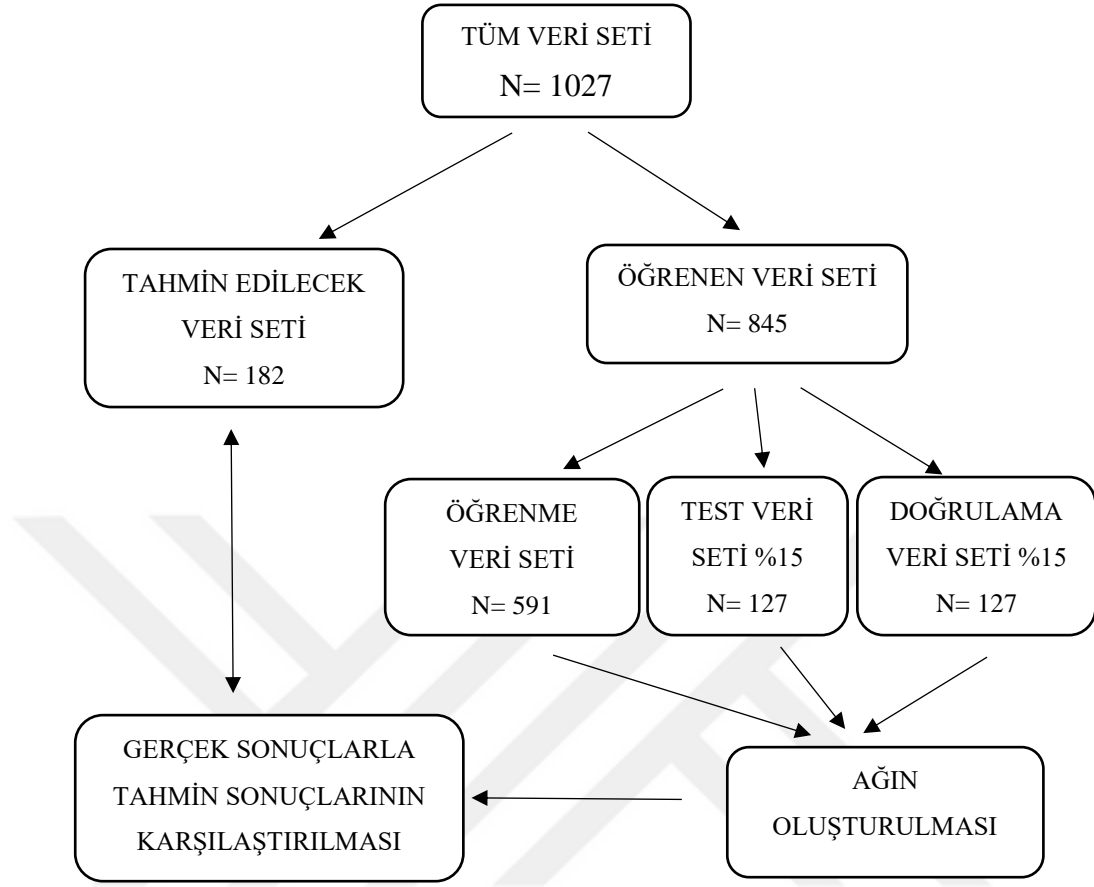
ilkokul ve ortaokul bölümlerinin birbirinden ayrılmasından dolayı belirlenen ortaokulların e-okul veri tabanında 4. Sınıfa ait veriler bulunmamaktadır. Belirlenen ortaokullardaki öğrencilerin ilkokul verilerine ulaşmak için bu okulların yakın çevresinde bulunan ilkokullar taranmış ve 2018 yılında LGS sınavına giren öğrencilerin 2013-2014 eğitim-öğretim yılında 4. sınıfta olması gerektiğinden dolayı bu döneme ait geçmiş dönem not çizelgelerine ulaşılmıştır. Yukarıda bahsedilen işlemler tekrar 4. sınıf verileri için uygulanmıştır. Sonuçta 1027 öğrencinin bu araştırmada kullanılmak üzere eksiksiz verisi elde edilmiştir.

Verilerin Analizi

Bu bölümde, veri analizi kısmında yapılan tüm işlemlere ayrıntılı olarak yer verilmiş ve veri analizi süreci detaylı bir şekilde anlatılmıştır.

Araştırma sorularını yanıtlamak üzere oluşturulan veri seti içerisinde; öncelikle Fen Bilimleri dersi başarılarının sınıf düzeyleri arasındaki ilişki düzeyini belirlemek amacıyla korelasyon analizi SPSS 23 bilgisayar programında yapılmıştır. Sonra öğrencilerin ilkokuldan itibaren (4., 5., 6., 7. ve 8. Sınıf) Fen Bilimleri ders başarıları ile LGS sınavı Fen Bilimleri alt testindeki doğru sayılarının ağ öğrenmesi ile tahmin edilmesi çalışması MATLAB (Artificial Neural Network) programında gerçekleştirilmiştir.

Veri seti, ağın oluşturulması ve araştırmanın amacını oluşturan problem durumlarının test edilmesi için ikiye ayrılmıştır. 1027 öğrenci verisi; Excel programında rastgele (random) seçilerek 845 öğrenci verisi “Öğrenilen Veri Seti” ve 182 öğrenci verisi “Tahmin Edilecek Veri Seti” olmak üzere ayrılmıştır. Bu ayırma işleminin temel amacı, en iyi ağ performansının bulunması ve sonrasında oluşturulan yapay sinir ağının ilk defa karşılaştığı yeni veri seti karşısında üretecek olduğu tahmin verilerinin performansının değerlendirilmesidir. Genel olarak yapılan çalışmalarda tüm veri setinin en az %15'inin tahmin verisi olarak kullanıldığı görülmektedir. Bu araştırma kapsamında da tüm veri setinin yaklaşık %18'i (N=182) ağın öğretiminden sonra tahmin verisi ile gerçek verinin karşılaştırılması için ayrılmıştır.



Şekil 13. Ağın oluşturulması için yapılan veri seti işlemleri.

Verilerin ayrıştırılması işlemi tamamlandıktan sonra araştırmanın birinci alt probleminde; 845 öğrencinin 4., 5., 6., 7., 8. Sınıf Fen Bilimleri yazılı sınav ve LGS Fen Bilimleri Alt Test doğru sayıları arasındaki ilişkiye Pearson Moment Çarpım Korelasyonu ile bakılmıştır.

Araştırmanın ikinci alt probleminde; istatistiksel çözümleme sürecinde yapay sinir ağı analizi kullanılmıştır. Matlab 2018a programının editör bölümünde yapay sinir ağı fonksiyonları işe koşulmuştur. Öğrencilerin 4., 5., 6., 7. ve 8. sınıf düzeylerinde Fen Bilimleri dersinde almış olduğu 29 adet 0-100 aralığında puanlanan yazılı sınav başarı notu ağın girdilerini, 2018 LGS sınavı Fen Bilimleri dersi alt testinde yapmış oldukları doğru sayısı ise ağın çıktı kısmını oluşturmaktadır. Araştırmada kategorik veri kullanılmamıştır. Bu veri seti içerisinde ağ öğrenme sağlarken, rastgele kendi içerisindeki verilerden seçkiler belirleyerek araştırmacı tarafından belirlenen öğrenme fonksiyonlarını kullanarak

bağımlı ve bağımsız deęişken arasındaki ilişkileri öğrenmeye çalışmaktadır. Ardından oluşturduęu aęın performansını test ederek, tahmin verisi üretmektedir. Aęın oluşturulma aşamaları aşağıda detaylı bir şekilde anlatılmıştır.

Aę Mimarisinin Oluşturulması

Bu araştırmada yapay sinir aęı ile modelleme ve yordama yaparken oluşturulan işlevsel kod bloklarıyla, bilgisayarın otomatik olarak farklı kombinasyonları denemesi ve performans göstergeleri ile korelasyon katsayılarından oluşan sonuçların bir tabloda oluşturulması sağlanmıştır. Ayrıca her bir deneme için aęın öğrenme, geçerlilik ve test sonuçlarını gösteren doğrusal regresyon grafięi, ortalama karesel hata performans grafięi, hata deęerleri grafięi ve aęın tahmin ettięi doęru sayıları ile öğrencilerin gerçek doęru sayılarının grafiksel karşılaştırılması yazdırıldı.

Matlab dilinde yazılan kod satırlarından birinci bölümde çalışma alanında bulunan daha önceki verilerin temizlenerek sıfırlanması ve üzerinde çalışılacak fen veri setinin program içerisine yüklenmesi sağlanmıştır. Hemen ardından bağımsız ve bağımlı deęişkenler yani aęın girdi ve çıktı verileri tanımlanmıştır. Daha sonra üçüncü katman olan gizli katmanda yer alacak gizli hücre sayısı belirlenmiştir. Yapay sinir aęı modellemesinde kesinleşmiş bir yöntem olmamakla birlikte optimum gizli hücre sayısını elde etmek için “geometrik piramit kuralı” olarak adlandırılan yöntem kullanılır. Girdi hücre sayısının i ve çıktı hücre sayısının j olduęu kabul edilirse bu aę için geometrik piramit kuralına göre gizli hücre sayısı, girdi ve çıktı hücre sayılarının çarpımının karekökünden küçük olamaz. Yine bu kural dahilinde gizli hücre sayısının üst sınırı ise girdi hücre sayısının iki katını geçmemelidir. Bu durumda araştırmanın aę mimarisinde kullanılacak gizli hücre sayısı 5 ile 58 arasında olmalıdır (Masters, 1995). Tablo 4’te bu bölümü anlatan kod satırları gösterilmiştir.

Tablo 4

Çalışma Alanının Temizlenmesi ve Veri Setinin Yüklenmesini Gösteren Kodlar

```
clear all; clc;  
load fenanaliz  
inputs = [input]; targets = [output];  
[i,j] = size(inputs);  
l= sqrt(i*j);  
k=i*2;  
NeuronNumbers=(floor(l):k);
```

İkinci bölümde yapay sinir ağında kullanılacak ağ tipi yani öğrenme algoritması belirlendi. Yapay sinir ağı uygulama başarısını belirleyen en önemli faktörler ağı yapısının seçimi ve öğrenme algoritmasının seçimidir. Ağ yapısı ise öğrenme algoritmasının seçiminde belirleyici rol oynar. Yapay sinir ağının geliştirilmesinde kullanılacak çok sayıda öğrenme algoritması bulunmaktadır. Bunlar içinde bazı algoritmaların bazı uygulamalar için daha uygun olduğu bilinmektedir. Bu çalışmada, yordama ve sınıflandırma problemleri için sıklıkla kullanılan “Çok Katmanlı Algılayıcı (Multilayer Perceptron) Modeli” sınıfından “İleri Kademeli Geri Yayılım (Feed Forward Backprop)” öğrenme algoritması seçildi. Sonraki kod satırlarında eğitim ağı için kullanılacak olan eğitim girdi ve çıktı setinin işleme fonksiyonları belirlendi. Öğrenme veri seti rastgele dağılım komutu kullanılarak üç kümeye ayrıldı. Araştırmada mevcut öğrenme setinin yüzde 70’lik bölümü eğitim için ayrıldı. Geriye kalan yüzde 30’luk bölümün yarısı geçerlilik (doğrulama) testi ve diğer yarısı da test işlemleri ve ağı başarısının ölçülmesi için ayrıldı. Daha sonra transfer fonksiyonu olarak logaritmik sigmoid fonksiyonu tanımlandı. Logsig fonksiyonu, tahmin amaçlı kullanılan geri yayılım ağ tipinde yaygın olarak kullanılmaktadır. Çünkü bu fonksiyon doğrusal olmayan veriler içinde anlamlı ve etkin sonuçlar vermektedir. 0-1 arasında sürekli artan bir fonksiyondur. Öğrenme fonksiyonu olarak Levenberg-Marquardt algoritması (trainlm) belirlendi. Levenberg-Marquardt öğrenme algoritması minimumu araştırma metodudur. Her bir iterasyon adımında hata yüzeyine parabolik yaklaşımla yaklaşılar ve parabolün o adım için çözümü oluşturur aynı zamanda diğer algoritmalara kıyasla oldukça hızlı sonuç üretir (Yetkin, 2014). Performans fonksiyonu olarak “MSE” hata kareleri ortalaması belirlendi. Bu metot ağı performansını, kare hataların ortalamasına göre seçer.

Tablo 5

Ağ Yapısı ve Özelliklerinin Belirlendiği Kodlar

```

for n=floor(l):k;
    hiddenLayerSize = n;
    net = feedforwardnet(hiddenLayerSize);
    net.inputs{1}.processFcns = {'removeconstantrows','mapminmax'};
    net.outputs{2}.processFcns = {'removeconstantrows','mapminmax'};

    net.divideFcn = 'dividerand';
    net.divideMode = 'sample';
    net.divideParam.trainRatio = 70/100;
    net.divideParam.valRatio = 15/100;
    net.divideParam.testRatio = 15/100;

    net.layers{1}.transferFcn = 'logsig';
    net.layers{2}.transferFcn = 'logsig';
    net.trainFcn = 'trainlm';
    net.performFcn = 'mse';

```

Ağın öğrenme parametreleri üçüncü bölümde yer almaktadır ve tablo 6’da gösterilmiştir. Bu aşamada performans hedefi, maximum doğrulama hataları, momentum katsayısı, öğrenme katsayısı ve ağın öğrenmesini durduracak çevrim sayısı gibi öğrenme performansını etkileyen parametreler seçildi.

Tablo 6

Ağın Öğrenme Parametrelerinin Belirlendiği Kodlar

```

net.trainParam.epochs = 1000;
net.trainParam.max_fail = 6;
net.trainParam.show = 25;
net.trainParam.goal = 0;
net.trainParam.min_grad = 1e-07;
net.trainParam.mu = 0.001;
net.trainParam.mu_dec = 0.1;
net.trainParam.mu_inc = 10;
net.trainParam.mu_max = 10000000000;

```

Dördüncü bölümde ağın girdi ve hedef verilerine göre öğrenme işlemi tanımlandı. Öğrenme işlemi gerçekleşikten sonra çıktı verileri ile hedef veriler arasındaki fark (hata) hesaplandı. Daha sonra öğrenilen ağın genel performans ve regresyon değerleri hesaplandı. Ayrıca ağın öğrenme, doğrulama (geçerlilik) ve test performans değerleri hesaplandı.

Tablo 7

Ağın Eğitim Aşamasının Tanımlandığı Kodlar

```
net.plotFcns = {'plotperform','plottrainstate','ploterrhist', ...  
                'plotregression', 'plotfit'};  
  
[net,tr] = train(net,inputs,targets);  
  
outputs = net(inputs);  
all_outputs(:,n) = outputs;  
errors = gsubtract(targets,outputs);  
all_error(:,n) = errors;  
  
AllPerformance(n) = perform(net,targets,outputs);  
AllResults(n) = regression(targets,outputs);  
  
trainTargets = targets .* tr.trainMask{1};  
TrainResults(n) = regression(trainTargets,outputs);  
TrainPerformance(n) = perform(net,trainTargets,outputs);  
  
valTargets = targets .* tr.valMask{1};  
ValidationResults(n) = regression(valTargets,outputs);  
ValPerformance(n) = perform(net,valTargets,outputs);  
  
testTargets = targets .* tr.testMask{1};  
TestResults(n) = regression(testTargets,outputs);  
TestPerformance(n) = perform(net,testTargets,outputs);
```

Ağın eğitimi tamamlanıp ve ağ için kullanılacak olan parametrelerin tamamı belirlendikten sonra ağın test edilmesi aşamasına geçildi. Beşinci bölümde daha önceden ayrıştırılan ve sisteme hiç tanıtılmamış 182 öğrencinin tahmin girdi verisi simüle edildi. Ağın tahmin değerleri ondalık sayı olarak çıktığı için en yakın sayıya yuvarlandı. Daha sonra öğrencilerin LGS Fen Bilimleri dersi alt testinde yaptıkları doğru sayıları ile ağın tahmin ettiği veriler arasındaki hata hesaplandı. Bir sonraki kod bloğunda hem öğrenme veri seti hem de tahmin veri seti için gerçek sonuçlarla ağın tahmin sonuçları arasındaki korelasyon katsayıları hesaplandı. Bu bölümü anlatan kodlar tablo 8’de gösterilmiştir.

Tablo 8

Ağın Simüle Edilerek Tahmin Performansının Belirlendiği Kodlar

```

tahmin_outputs = sim(net,tahmin_input);
tahmin_outputs1 = round(tahmin_outputs);
all_tahmin_outputs(:, :, n) = tahmin_outputs1;
tahmin_errors = gsubtract(tahmin_output, all_tahmin_outputs(:, :, n));
all_tahmin_errors(:, :, n) = tahmin_errors;

corrolation_coefficients(:, :, n) = corrcoef(outputs, targets);
CorrolationCoefficients(n) = corrolation_coefficients(1, 2, n);
tahmin_corrolation_coefficients(:, :, n) = corrcoef(tahmin_outputs, tahmin_output);
TahminCorrolationCoefficients(n) = tahmin_corrolation_coefficients(1, 2, n);

```

Son bölümdeki kod satırları, her bir gizli hücre sayısında yapılan ağ öğrenmesinden ve test sonuçlarından elde edilen öğrenme, geçerlilik, test ve genel performans değerleri ile bu değerlerin regresyon sonuçları tablosunu oluşturmak için yazıldı. Ayrıca öğrenme, geçerlilik ve test sonuçlarını gösteren doğrusal regresyon grafikleri, ortalama karesel hata performans grafiği, hata değerleri grafiği (+2,-2 aralığında en iyi sonucu veren grafik) ve ağın tahmin ettiği doğru sayıları ile öğrencilerin gerçek doğru sayılarının karşılaştırılması grafikleri her gizli hücre sayısında yapılan ağ öğrenmesi için oluşturuldu ve kayıt edildi.

Tablo 9

Ağın Sonuç Grafiklerinin ve Tablosunun Oluşturulduğu Kodlar

```

A_max_Tah_Corr_Coef=find(TahminCorrolationCoefficients==max(TahminCorrolati
onCoefficients));
figure(1)
plot(tahmin_output, 'DisplayName', 'girilen_ssonuclar');
hold on;
plot(all_tahmin_outputs(:, :, A_max_Tah_Corr_Coef), 'DisplayName', 'tahmin_ssonuclar
i');
xlabel('Öğrenci sayisi');
ylabel('Gerçek ve tahmin dogru sayisi');
hold off;
A=all_tahmin_errors(:, :, n);
A_error=A(abs(A) < 3);
A_Number_of_error(n)=numel(A_error(A_error < abs(3)));
A_max_Tah_Corr_Coef_sayisi = A_Number_of_error(A_max_Tah_Corr_Coef);
figure(2)
A_hist=histogram(all_tahmin_errors(:, :, A_max_Tah_Corr_Coef));
xlabel('Tahmini Hata Sayisi Araligi');


```

Tablo 9 devamı

Ağın Sonuç Grafiklerinin ve Tablosunun Oluşturulduğu Kodlar

```
ylabel('Aralıktaki doğru sayısı');  
  
figure (n+2)  
    plotregression(trainTargets,outputs,'Training',valTargets,outputs,'Validation',...  
        testTargets,outputs,'Test',targets,outputs,'All')  
figure (n+3)  
    plotperform(tr)  
  
end  
  
TahminCorrolationCoefficients=TahminCorrolationCoefficients';  
CorrolationCoefficients=CorrolationCoefficients';  
TrainResults=TrainResults'; ValidationResults=ValidationResults';  
TestResults=TestResults'; AllResults=AllResults';  
TrainPerformance=TrainPerformance'; ValPerformance=ValPerformance';  
TestPerformance=TestPerformance'; AllPerformance=AllPerformance';  
  
Fen_sonucu = table(NeuronNumbers, TahminCorrolationCoefficients,  
    CorrolationCoefficients, ...  
    TrainResults, ValidationResults, TestResults, AllResults,...  
    TrainPerformance, ValPerformance, TestPerformance, AllPerformance);
```

Bu araştırmada en iyi öğrenme sağlayan ağ mimarisini bulmak için yazılan kod bloğu her çalıştırıldığında tek gizli katmanlı 5 ile 58 nöron sayısı aralığında toplam 54 ağ elde edilmiştir. Oluşturulan kod bloğu 10 kez çalıştırılıp, bu 10 çalıştırma içerisinde performansı en yüksek olan performans öğrenme, performans geçerlilik ve performans test değerleri ile ağın öğrenme aşamasında oluşan öğrenme, geçerlilik (doğrulama) ve test süreçlerinin korelasyon katsayı değerleri birlikte kaydedilmiştir. Bu durumda problem durumuna en uygun ağ mimarisini belirlenirken 540 farklı ağ mimarisi incelenmiştir. Aşağıdaki şekil 14'te oluşturulan bir ileri kademeli geri yayılım ağ tipinden tek gizli katmanlı ağ mimarisinin oluşumu gösterilmiştir.



Şekil 14. 29 girdi değişkenli, bir gizli katmanlı, 20 gizli hücre sayılı örnek ileri kademeli geri yayılım ağ mimarisi.

Çok katmanlı bir yapay sinir ağında, en iyi ve en önemli performans ölçütü, modelleme zamanı veya eğitim zamanı gibi birçok ölçüt olmasına rağmen, tahminin doğruluğudur. Doğruluk ölçütü, gerçek değer ile tahmin edilen değerler arasındaki fark olarak tanımlanır. Bu fark, tahmin hatası olarak adlandırılır (Zhang, 1998). Bir yapay sinir ağının performansı denilince de öğrenme yeteneğinin ölçülmesi anlaşılır. Yani, yapay sinir ağı modelinin verileri iyi öğrenip öğrenmediği ölçülmektedir. Bu araştırmada model performansı değerlendirilirken, simüle (tahmin) edilmiş ağı korelasyon katsayı (R) değeri 1'e en yakın modeller daha başarılı performans göstermektedirler. Yine araştırmalarda sıklıkla kullanılan önemli bir ölçütte karekök ortalama kareler hatası (RMSE) değeridir. Bu değer tahminleyicinin tahmin ettiği değerler ile gerçek değerleri arasındaki uzaklığın bulunmasında sıklıkla kullanılan, hatanın büyüklüğünü ölçen kuadratik bir metriktir. RMSE tahmin hatalarının (kalıntıların) standart sapmasıdır (Zhang, 1998). Aynı zamanda ağı öğrenme performansındaki eğitim, doğrulama ve test R değerlerinin birbirine yakın olması, ağı en yüksek değeri olmasa bile daha dengeli ve tutarlı sonuçlara sahip olduğu manasına gelmektedir. Birbirine uzak R değerleri ise, eğitim, doğrulama ve test aşamalarının her birinde ağı tutarsız sonuçlar bulduğu manasına gelmektedir (Yılmaz, 2015).

Üçüncü Bölüm

Bulgular

Bu kısımda araştırmanın amaçları doğrultusunda verilerin analiz edilmesiyle elde edilen bulgular ve yorumlar ele alınmıştır.

Birinci Alt Probleme İlişkin Bulgular

Öğrencilerin ilkokuldan itibaren 4., 5., 6., 7. ve 8. sınıf Fen Bilimleri dersi akademik başarıları ile LGS sınavı fen bilimleri alt testi başarıları arasındaki ilişki düzeyi araştırılırken aşağıdaki sorulara cevap aranmıştır:

1) 4. Sınıf Fen Bilimleri Yazılı Sınav ile LGS FEN Bilimleri Alt Test doğru sayıları arasında nasıl bir ilişki vardır?

2) 5. Sınıf Fen Bilimleri Yazılı Sınav ile LGS FEN Bilimleri Alt Test doğru sayıları arasında nasıl bir ilişki vardır?

3) 6. Sınıf Fen Bilimleri Yazılı Sınav ile LGS FEN Bilimleri Alt Test doğru sayıları arasında nasıl bir ilişki vardır?

4) 7. Sınıf Fen Bilimleri Yazılı Sınav ile LGS FEN Bilimleri Alt Test doğru sayıları arasında nasıl bir ilişki vardır?

5) 8. Sınıf Fen Bilimleri Yazılı Sınav ile LGS FEN Bilimleri Alt Test doğru sayıları arasında nasıl bir ilişki vardır?

Fen Bilimleri Yazılı Sınav ve LGS Fen Bilimleri Alt Test Doğru Sayılarına İlişkin Aritmetik Ortalama ve Standart Sapma sonuçları Tablo 11 de verilmektedir.

Tablo 10

Fen Bilimleri Yazılı Sınav ve LGS Fen Bilimleri Alt Test Doğru Sayılarına İlişkin Aritmetik Ortalama ve Standart Sapma

Değişkenler	Ortalama	Standart Sapma	N
4. Sınıf Fen Bilimleri yazılı Sınav	82,25	12,53	845
5. Sınıf Fen Bilimleri yazılı Sınav	73,75	14,65	845
6. Sınıf Fen Bilimleri yazılı Sınav	70,46	16,37	845
7. Sınıf Fen Bilimleri yazılı Sınav	70,42	17,05	845
8. Sınıf Fen Bilimleri Yazılı Sınav	72,25	18,12	845
LGS Fen Bilimleri Alt Test Doğru Sayısı	9,44	3,95	845

Tablo incelendiğinde, 4., 5., 6., 7., 8. Sınıf Fen Bilimleri yazılı Sınavlarına ait en yüksek ortalamanın sınıf düzeyine göre sırasıyla 82.25 ile 4. Sınıf düzeyine ait olduğu görülmektedir. LGS Fen Bilimleri Alt Test Doğru Sayılarına ait ortalamanın da 9.44 olduğu tespit edilmiştir.

Değişkenler arasındaki ilişkileri incelemek için değişkenler arasındaki korelasyonlara bakılmış ve sonuçlar Tablo 12 de verilmektedir.

Tablo 11

Fen Bilimleri Yazılı Sınav ve LGS Fen Bilimleri Alt Test Doğru Sayıları Arasındaki Korelasyonlar

Değişkenler	4. Sınıf	5. Sınıf	6. Sınıf	7. Sınıf	8. Sınıf	LGS Fen Bilimleri Alt Test
4. Sınıf	1					
5. Sınıf	,72**	1				
6. Sınıf	,73**	,82**	1			
7. Sınıf	,65**	,74**	,83**	1		
8. Sınıf	,60**	,68**	,76**	,80**	1	
LGS Fen Bilimleri Alt Test	,57**	,62**	,69**	,66**	,70**	1

** p< 0.01

Tablo incelendiğinde, korelasyon katsayılarının 0,57 ile 0,83 arasında değiştiği, tüm korelasyon katsayılarının 0.01 manidarlık düzeyinde anlamlı olduğu görülmektedir.

Tabloda verilen LGS Fen Bilimleri Alt Testi ile Fen Bilimleri Yazılı Sınavları arasındaki korelasyonlar incelendiğinde en yüksek manidar korelasyonun 8. Sınıf fen bilimleri yazılı sınav arasında ($r=0,70$) olduğu, en düşük manidar korelasyonun LGS Fen Bilimleri Alt Testi ile 4. Sınıf fen bilimleri yazılı sınav arasında ($r=0,57$) olduğu görülmektedir.

Fen Bilimleri Yazılı Sınavlar arasındaki korelasyonlar incelendiğinde en yüksek manidar korelasyonun 7. Sınıf fen bilimleri yazılı sınav ile 6. Sınıf fen bilimleri yazılı sınav arasında ($r=0,83$), en düşük manidar korelasyonun 8. Sınıf fen bilimleri yazılı sınavı ile 4. Sınıf fen bilimleri yazılı sınav arasında ($r=0,60$) olduğu görülmektedir.

İkinci Alt Probleme İlişkin Bulgular

“Öğrencilerin ilkokuldan itibaren (4., 5., 6., 7. ve 8. sınıf) fen bilimleri ders başarıları, LGS sınavı fen bilimleri alt testindeki doğru sayılarını ne derecede tahmin etmektedir?” sorusuna yanıt vermek amacıyla yapay sinir ağı ile oluşturulan ağ mimarilerinin analizlerinden elde edilen bulgulara yer verilmiştir. Öncelikle oluşturulan ağ mimarisinin özelliklerini gösteren Tablo 13 aşağıda yer almaktadır.

Tablo 12

Oluşturulan Ağ Mimarisinin Özelliklerini Gösteren Tablo

<i>Deneme Sayısı</i>	<i>Ağ Tipi</i>	<i>Performans Fonksiyonu</i>	<i>Transfer Fonksiyonu</i>	<i>Öğrenme Fonksiyonu</i>	<i>Katman Sayısı</i>	<i>Gizli Katman Sayısı</i>	<i>Gizli Hücre Sayısı</i>
10	İleri Kademeli Geri Yayılım (FeedForward Backpropagation)	Ortalama Karesel Hata (MSE)	Logaritmik Sigmoid (LOGSIG)	Levenberg-Marquardt (TRAINLM)	3	1	5-58

Aşağıdaki Tablo 14’ te ağın öğrenme aşamasında 845 öğrencinin verisi ile ağın öğrenmesinin gerçekleştiği ve 182 öğrencinin daha önceden yapay sinir ağına tanıtılmamış verisi ile simüle edilerek tahmin etme performansından elde edilmiş birinci deneme sonucu oluşan değerler yer almaktadır.

Tablo 13

Oluşturulan Yapay Sinir Ağı Modelinin Çalıştırılması İle Elde Edilen Birinci Deneme Sonuçları

<i>Gizli Hücre Sayısı</i>	<i>Tahmin Korelasyon Katsayısı (R)</i>	<i>Öğrenme Korelasyon Katsayısı (R)</i>	<i>Eğitim Sonucu</i>	<i>Doğrulama Sonucu</i>	<i>Test Sonucu</i>	<i>Genel Sonuç</i>	<i>En İyi Doğrulama Performansı</i>	<i>Kök Ortalama Kare Hataları (RMSE) Değeri</i>
5	0,7141	0,7901	0,8003	0,7641	0,7750	0,7901	6,4882	2,4409
6	0,7470	0,7866	0,7932	0,7797	0,7682	0,7866	6,7910	2,4461
7	0,5804	0,7078	0,7147	0,7357	0,6623	0,7078	10,0017	3,2383
8	0,7353	0,7775	0,7980	0,7650	0,6893	0,7775	6,2969	2,5068
9	0,6799	0,7947	0,7978	0,7884	0,7876	0,7947	5,4257	2,4047
10	0,6774	0,7967	0,8296	0,6756	0,7573	0,7967	7,4368	2,4068
11	0,6850	0,8007	0,8091	0,7999	0,7596	0,8007	6,2218	2,4036
12	0,6865	0,7803	0,7999	0,6922	0,7753	0,7803	6,2357	2,5096
13	0,6657	0,8119	0,8387	0,7316	0,7897	0,8119	8,4973	2,4195
14	0,7225	0,7803	0,7941	0,7737	0,7248	0,7803	7,6201	2,4773
15	0,6851	0,7916	0,8114	0,7519	0,7417	0,7916	6,4632	2,4242
16	0,6978	0,8033	0,8493	0,6872	0,6868	0,8033	8,3196	2,3757
17	0,6569	0,7616	0,7857	0,7137	0,7083	0,7616	9,2031	2,9964

Tablo 13 devamı

Oluşturulan Yapay Sinir Ağı Modelinin Çalıştırılması İle Elde Edilen Birinci Deneme Sonuçları

<i>Gizli Hücre Sayısı</i>	<i>Tahmin Korelasyon Katsayısı (R)</i>	<i>Öğrenme Korelasyon Katsayısı (R)</i>	<i>Eğitim Korelasyon Katsayısı (R)</i>	<i>Doğrulama Korelasyon Katsayısı (R)</i>	<i>Test Korelasyon Katsayısı (R)</i>	<i>Genel Korelasyon Katsayısı (R)</i>	<i>En İyi Doğrulama Performansı</i>	<i>Karekök Ortalama Hata Kareleri (RMSE) Değeri</i>
18	0,6607	0,7664	0,7917	0,7444	0,6775	0,7664	8,1968	2,7237
19	0,6549	0,7516	0,7650	0,6290	0,7892	0,7516	8,8785	2,6874
20	0,4869	0,8263	0,9089	0,5986	0,7131	0,8263	12,7183	2,3033
21	0,6780	0,7742	0,7918	0,7785	0,6876	0,7742	7,4129	2,6536
22	0,7381	0,7826	0,7740	0,7958	0,8112	0,7826	6,1646	2,4789
23	0,6425	0,7591	0,7791	0,6849	0,7313	0,7591	6,7135	2,5848
24	0,7109	0,7947	0,8362	0,6582	0,6846	0,7947	9,6449	2,6748
25	0,6930	0,8027	0,8407	0,6860	0,7695	0,8027	10,2580	2,4262
26	0,6278	0,7827	0,8274	0,6346	0,7068	0,7827	9,6059	2,6031
27	0,4243	0,6265	0,7423	0,3885	0,4330	0,6265	34,2603	4,4183
28	0,6609	0,7849	0,7908	0,7945	0,7505	0,7849	6,9584	2,4713
29	0,6847	0,7536	0,7679	0,7477	0,6976	0,7536	6,1929	2,6083
30	0,7179	0,8070	0,8376	0,6961	0,7502	0,8070	7,3668	2,3440
31	0,6661	0,7311	0,7753	0,6362	0,6059	0,7311	8,6994	2,7855

Tablo 13 devamı

Oluşturulan Yapay Sinir Ağı Modelinin Çalıştırılması İle Elde Edilen Birinci Deneme Sonuçları

<i>Gizli Hücre Sayısı</i>	<i>Tahmin Korelasyon Katsayısı (R)</i>	<i>Öğrenme Korelasyon Katsayısı (R)</i>	<i>Eğitim Korelasyon Katsayısı (R)</i>	<i>Doğrulama Korelasyon Katsayısı (R)</i>	<i>Test Korelasyon Katsayısı (R)</i>	<i>Genel Korelasyon Katsayısı (R)</i>	<i>En İyi Doğrulama Performansı</i>	<i>Karekök Ortalama Hata Kareleri (RMSE) Değeri</i>
32	0,6384	0,8061	0,8465	0,7145	0,7065	0,8061	8,2736	2,3438
33	0,6696	0,7996	0,8263	0,7351	0,7469	0,7996	7,4577	2,4102
34	0,5016	0,8298	0,8875	0,7133	0,7234	0,8298	8,3397	2,2098
35	0,6196	0,7277	0,7934	0,5769	0,5753	0,7277	9,6896	2,7700
36	0,6491	0,8135	0,8472	0,7548	0,7131	0,8135	6,8186	2,3210
37	0,7450	0,8072	0,8242	0,7047	0,8217	0,8072	6,8942	2,3517
38	0,6193	0,8107	0,8840	0,7018	0,5967	0,8107	8,6993	2,3344
39	0,6839	0,8301	0,8681	0,7282	0,7585	0,8301	8,0786	2,2076
40	0,6717	0,7692	0,7851	0,7130	0,7618	0,7692	9,0898	2,6656
41	0,6734	0,8177	0,8637	0,7248	0,6865	0,8177	7,1909	2,2826
42	0,6543	0,7904	0,8414	0,6778	0,6692	0,7904	8,8254	2,5809
43	0,5590	0,7828	0,8230	0,6891	0,6868	0,7828	8,0834	2,5514
44	0,6917	0,7822	0,7907	0,7657	0,7581	0,7822	5,9490	2,5116
45	0,5847	0,8057	0,8548	0,7115	0,6669	0,8057	7,9318	2,6331

Tablo 13 devamı

Oluşturulan Yapay Sinir Ağı Modelinin Çalıştırılması İle Elde Edilen Birinci Deneme Sonuçları

<i>Gizli Hücre Sayısı</i>	<i>Tahmin Korelasyon Katsayısı (R)</i>	<i>Öğrenme Korelasyon Katsayısı (R)</i>	<i>Eğitim Korelasyon Katsayısı (R)</i>	<i>Doğrulama Korelasyon Katsayısı (R)</i>	<i>Test Korelasyon Katsayısı (R)</i>	<i>Genel Korelasyon Katsayısı (R)</i>	<i>En İyi Doğrulama Performansı</i>	<i>Karekök Ortalama Hata Kareleri (RMSE) Değeri</i>
46	0,6986	0,7765	0,7791	0,7983	0,7532	0,7765	6,1491	2,6625
47	0,6405	0,7823	0,8044	0,7246	0,7386	0,7823	7,6192	2,4686
48	0,7422	0,7768	0,7897	0,7398	0,7609	0,7768	7,1975	2,5072
49	0,7230	0,8080	0,8359	0,7556	0,7278	0,8080	6,3361	2,3334
50	0,3703	0,6737	0,7433	0,4346	0,5534	0,6737	11,4223	2,9452
51	0,7179	0,7955	0,7962	0,8215	0,7772	0,7955	5,0194	2,4012
52	0,6821	0,8254	0,8922	0,7095	0,6465	0,8254	8,4723	2,2376
53	0,7288	0,7875	0,8037	0,7125	0,7797	0,7875	6,9792	2,4399
54	0,6257	0,8432	0,9273	0,6080	0,7068	0,8432	10,4177	2,1405
55	0,6516	0,7908	0,8360	0,7717	0,5908	0,7908	6,6804	2,4281
56	0,6950	0,7870	0,8290	0,6557	0,6991	0,7870	8,7874	2,4633
57	0,6402	0,7249	0,7599	0,6452	0,6696	0,7249	10,9019	2,8678
58	0,6755	0,8306	0,8912	0,6928	0,7193	0,8306	11,5145	2,5863

Ağ mimarisinin oluşturulması aşamasında yapılan yazılım ile hem öğrenme veri seti hem de tahmin veri seti aynı anda kullanılmıştır. Buradaki amaç işlem basamaklarına göre sırasıyla ağın öğrenme performansını ölçüp sonrada tahmin sonuçlarıyla öğrencilerin gerçek verilerini karşılaştırarak en iyi tahmin performansını gösteren ağ modelini keşfetmektir. Yapay sinir ağının model performansı değerlendirilirken, simüle edilmiş ağın korelasyon katsayı (R) değerine bakılacağı yukarıda belirtilmiştir. Ayrıca en uygun ağ performansı belirlenirken öğrenme korelasyon katsayısı (R) değeri ile karekök ortalama hata kareleri (RMSE) değeri kriter olarak incelenmiştir.

Tablo 14 incelendiğinde birinci deneme sonunda beşten elli sekize kadar olan gizli hücre sayısına göre ağın göstermiş olduğu performanslara bakıldığında en iyi performansı Tahmin R= 0.7470 değeri ile 6 gizli hücre sayılı mimarinin oluşturduğu görülmektedir. Diğer değerleri incelendiğinde Öğrenme R= 0.7866, Eğitim R= 0.7932, Doğrulama R= 0,7797, Test= 0,7682 ve Karekök Ortalama Hata Kareleri değeri 2,4461'dir.

Öte yandan 54 gizli hücre sayısına sahip ağ mimarisinde Öğrenme R= 0,8432 bu deneme içindeki en yüksek değer ve RMSE= 2,1405 değeri 1'e en yakın değerdir. Ancak bu ağın diğer değerlerine bakıldığında Eğitim R= 0,9273, Doğrulama R= Test R= 0,7068 değerleri arasında çok yüksek farklar olduğu görülmektedir. Bu değerlerdeki tutarsızlıktan dolayı ağın Tahmin R= 0,6257 değeri düşük çıkmıştır.

Genel olarak bakıldığında 12 ağ mimarisinin tahmin korelasyon katsayı değerinin 0.70'in üzerinde olduğu görülmektedir. Geriye kalan 42 ağ mimarisinin tahmin korelasyon katsayı değeri 0.30 ile 0.70 arasında bulunduğu görülmektedir.

Bu çalışma kapsamında hazırlanan algoritma toplam 10 kez çalıştırılmış ve her denemeden sonra oluşan ağ mimarilerinin sonuç tabloları yukarıda birinci deneme sonuçlarının yer aldığı tablo 14'teki gibi kayıt edilmiştir. Ayrıca her denemedeki en iyi sonuçlara ait korelasyon katsayı grafikleri, histogram grafikleri ve tahmin sonuçları ile gerçek sonuç verilerinin karşılaştırıldığı grafikler de kayıt edilmiştir. Aşağıdaki Tablo 15 de her denemeye ait en iyi ağ performanslarını içeren sonuçlar paylaşılmış ve tabloya ait bulgulara yer verilmiştir.

Tablo 14

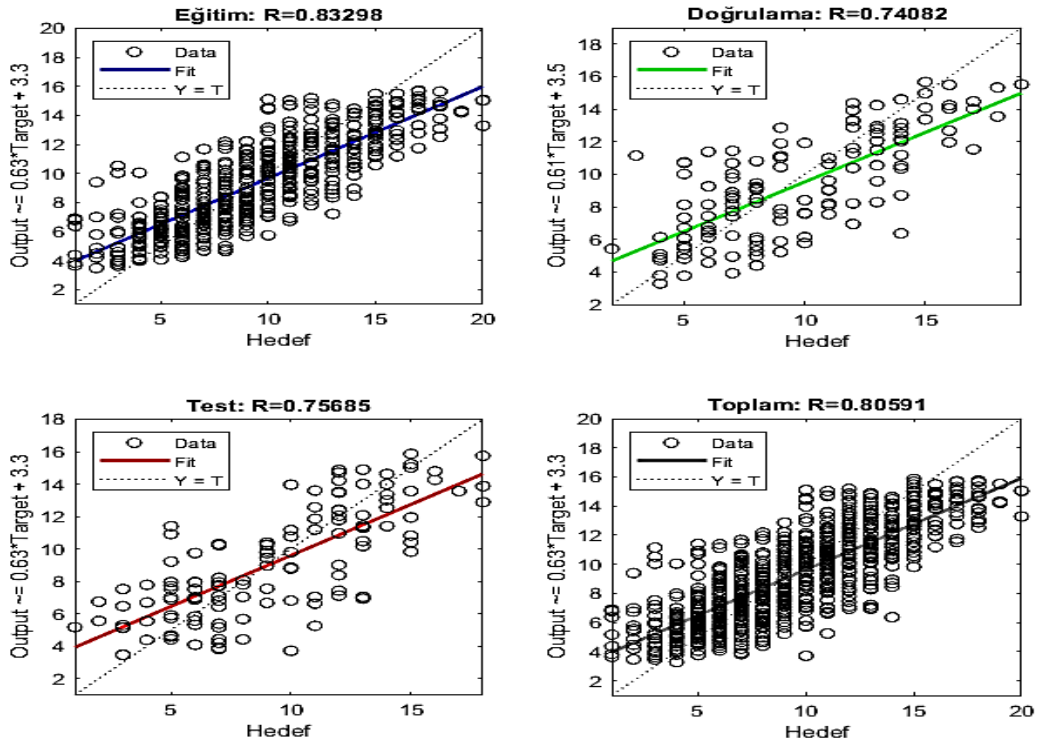
On Denemede Elde Edilen En İyi Performansları Gösteren Çizelge

<i>Deneme Sayısı</i>	<i>Her Denemede En İyi Performansı Veren Gizli Hücre Sayısı</i>	<i>Tahmin Korelasyon Katsayısı (R)</i>	<i>Öğrenme Korelasyon Katsayısı (R)</i>	<i>Eğitim Korelasyon Katsayısı</i>	<i>Doğrulama Korelasyon Katsayısı</i>	<i>Test Korelasyon Katsayısı</i>	<i>Genel Korelasyon Katsayısı</i>	<i>En İyi Doğrulama Performansı</i>	<i>Karekök Ortalama Hata Kareleri (RMSE) Değeri</i>
1.	6	0,7470	0,7866	0,7932	0,7797	0,7682	0,7866	6,7910	2,4461
2.	24	0,7506	0,8059	0,8329	0,7408	0,7568	0,8059	7,0282	2,3504
3.	6	0,7398	0,7766	0,7988	0,7984	0,6534	0,7766	5,4728	2,5763
4.	41	0,7396	0,7882	0,8049	0,7364	0,7553	0,7882	6,0488	2,4349
5.	38	0,7394	0,7779	0,7965	0,7415	0,7340	0,7779	6,8253	2,4879
6.	13	0,7333	0,7885	0,7989	0,7894	0,7531	0,7885	5,6871	2,4363
7.	41	0,7487	0,7888	0,8036	0,7447	0,7655	0,7888	6,7137	2,4450
8.	36	0,7216	0,7897	0,8206	0,6999	0,7502	0,7897	7,5789	2,4491
9.	30	0,7365	0,7713	0,7920	0,7073	0,7290	0,7713	7,2343	2,5369
10.	45	0,7493	0,8020	0,8021	0,8271	0,7785	0,8020	4,9762	2,3705

Tablo 15 incelendiğinde her bir denemedeki en iyi performanslara ait gizli hücre sayılarına bakıldığında 5-58 arasında farklı değerler gösterdiği görülmektedir. On kez deneme sonucuna göre iki kez 6 gizli hücre sayısı iki kez de 41 gizli hücre sayısı ile en iyi performansa ulaşılmıştır.

LGS Fen Bilimleri Alt Testinde öğrencilerin yaptığı doğru sayılarının tahmin edilmesi ve ağın öğrenmesinin sağlanabilmesi için yapılan denemeler arasında en iyi performansı sağlayan ağ mimarileri incelendiğinde, ikinci deneme de 24 gizli hücre sayısı ve Tahmin R= 0.7506 değeri ile ağın geneldeki en iyi ağ performansı olduğu görülmektedir. Ayrıca bu ağ mimarisinin diğer değerlerine bakıldığında Öğrenme R= 0.8059, Eğitim R= 0.8329, Test R= 0.7568, Doğrulama Performans değeri 7.0282, RMSE= 2.3504'tür. Bu değerlerden kriter olarak gözlemlenen performanslara bakılarak diğer ağ mimarileri ile karşılaştırıldığında, 1'e en yakın öğrenme korelasyon katsayı değerine sahip olduğu ve karekök ortalama hata kareleri değerinin en düşük olduğu söylenebilir.

En iyi performansı gösteren ağ mimarisinin eğitim, doğrulama ve test sonuçlarına ilişkin regresyon katsayılarını ve eğrisini gösteren grafik aşağıdaki şekil 15'te gösterilmiştir.




Şekil 15. Öğrenme, doğrulama ve test süreçlerine ilişkin regresyon grafikleri.

Şekildeki grafikler incelendiğinde ağıın regresyon değerleri eğitim aşaması için $R= 0.83298$, doğrulama aşaması için $R= 0.74082$ ve test aşaması için $R=0.75685$ olduğu görülmektedir. Uygunluk eğrilerine bakıldığında, ağıın öğrendiği verilerin bu eğri üzerinde kümelenildiği görülmektedir. Toplam R değerini ifade eden regresyon katsayısı, 845 öğrencinin girdi verisini ağa tanıtarak öğrendiği çıktı değerleri ile gerçek verilerin korelasyonel olarak karşılaştırılmasını ifade etmektedir. Yani LGS Fen Bilimleri Alt Testinde öğrencilerin yaptığı doğru sayıları ile yapay sinir ağının ürettiği doğru sayıları arasında ($R=0.8329$) istatistiksel olarak ilişki olduğu görülmektedir. Buna göre, gerçek veriler ile ağıın ürettiği veriler arasında yüksek düzeyde ilişki olduğu yorumu yapılarak, ağıın başarılı bir modelleme yaptığı söylenebilir.


Yapay sinir ağının öğrenme süreci tamamlandıktan sonra ağıın daha önce görmediği, araştırmanın en başında tahmin verisi olarak ayrılan 182 kişinin girdi değerleri ile mevcut ağ yapısı ve bağlantıları kullanılarak LGS Fen Bilimleri Alt Testinde öğrencilerin yaptığı doğru sayıları tahmin ettirilmiştir. Ağıın simüle edildikten sonra tahmin ettiği doğru sayıları ile öğrencilerin gerçekte sınavda yaptıkları doğru sayılarını içeren veri seti ile karşılaştırıldığında $r= 0.7506$ ($p<0.001$) korelasyonel ilişki bulunmuştur. Bu durumda ağıın öğrenmesi sonucu oluşan tahmin değerleri ile gerçek değerler arasında yüksek düzey ilişki saptanmıştır. Bu bulgudan hareketle yapay sinir ağının, öğrencilerin LGS Fen Bilimleri Alt testindeki yaptıkları doğru sayılarını iyi derecede yordadığı söylenebilir.

Aşağıdaki şekil 16'da yapay sinir ağının 182 öğrencinin, ilkokuldan itibaren (4., 5., 6., 7. ve 8. sınıf) fen bilimleri ders başarılarından hareketle tahmin ettiği doğru sayıları ile sınavda yapmış oldukları gerçek doğru sayılarının karşılaştırmasını içeren grafik verilmiştir.



Şekil 16. Tahmin veri seti kullanılarak ağı tahmin ettiği başarı notları ile kişilerin gerçek başarı notlarının grafiksel karşılaştırılması.

Şekil 17 incelendiğinde öğrencilerin ağ tarafından tahmin edilen doğru sayıları ile sınavda yaptıkları gerçek doğru sayılarını gösteren çizgilerin paralellik sağladığı ve birçok yerde çakıştığı görülmektedir. Tahmin başarısının daha iyi anlaşılabilmesi için ağın hata değerlerini gösteren histogram grafiği aşağıda verilmiştir.



Şekil 17. Tahmin edilen ağın hata değerlerinin dağılımı.

Öğrencilerin LGS Fen Bilimleri Alt Testinde yer alan 20 sorudan yaptıkları doğru sayısı ile ağın tahmin ettiği doğru sayılarından oluşan hata değerleri yukarıdaki histogramda gösterilmiştir. Tahmin edilen doğru sayılarının hata değerlerinin büyük bir çoğunluğunun $[-2, +2]$ aralığında olduğu görülmektedir ($N=124$). Tahmin edilen doğru sayısı, gerçekte yapılan doğru sayısına göre hata değeri 3 (negatif veya pozitif yönlü) olan doğru sayısı $N=21$ 'dir. Ayrıca $N=47$ öğrencinin doğru sayısını 4 ve üzeri (negatif veya pozitif yönlü) hata ile yanlış tahmin ettiği görülmektedir.

Dördüncü Bölüm

Sonuç Tartışma ve Öneriler

Sonuç

Bu araştırmada öğrencilerin, LGS Fen Bilimleri dersi alt testinde yaptıkları doğru sayısını yordama da bir üst sınıf seviyesindeki başarılarıyla da ilişkilendirmek suretiyle ilkokul 4. sınıftan itibaren Fen Bilimleri derslerindeki yazılı sınav sonuçlarının etkisi incelenmiştir.

Öncelikle 845 öğrencinin 4., 5., 6., 7., 8. Sınıf Fen Bilimleri dersi yazılı sınavlarına ait ortalamalar ile LGS Fen Bilimleri Alt Testinde yapmış oldukları doğru sayısı arasındaki ilişkiyi belirlemek üzere yapılan Pearson Çarpım Moment Korelasyon analizi sonucunda tüm değişkenler arasında istatistiksel açıdan $p < 0.01$ düzeyinde pozitif yönde anlamlı bir ilişki saptanmıştır.

LGS Fen Bilimleri Alt Testi ile Fen Bilimleri Yazılı Sınavları arasındaki korelasyonlar incelendiğinde en yüksek korelasyonun 8. Sınıf fen bilimleri yazılı sınav arasında ($r=0,70$) olduğu, en düşük korelasyonun LGS Fen Bilimleri Alt Testi ile 4. Sınıf fen bilimleri yazılı sınav arasında ($r=0,57$) olduğu görülmektedir.

2018 Liseye Geçiş Sınavı'nda soruların kapsamı 8.sınıf müfredatından oluşmaktadır. Buna rağmen araştırmada diğer sınıf düzeylerinde de LGS Fen Bilimleri alt testi başarısı ile orta ve yüksek düzey ilişkinin bulunmasının; Fen Bilimleri Dersi Öğretim Programının 3. sınıftan 8.sınıfa kadar sarmal yapıda olması ve sınıf düzeyi arttıkça bilgi, anlayış ve becerilerin derinliğinin artarak kapsamının genişlemesiyle alakalı olduğu söylenebilir.

Araştırmanın ikinci alt probleminin çözümünde yapay sinir ağları teknolojisi kullanılarak en iyi ağ mimarisini oluşturmak üzere daha önceki yapılan çalışmalarda incelenerek farklı tasarımlar ve kombinasyonlar denenmiştir. Bu araştırmada ağı eğitilmesi ve test işlemleri için 1027 öğrencinin veri seti ikiye ayrılmıştır. 845 öğrencinin verisi ağı eğitilmesi işlemlerinde, 182 öğrenci verisi de eğitilen ağı tahmin performansının değerlendirilmesinde kullanılmıştır. MATLAB 2018a programının editör bölümünde en iyi model performansı ile bu modelin

tahmin yeteneğinin değerlendirilmesi amacıyla kod satırları kullanılarak yazılım oluşturulmuştur. 54 farklı ağ mimarisi, 10 kez denenerek toplam 540 ağ mimarisi içinde elde edilen sonuçlardan en iyi tahmin korelasyon katsayısı, en iyi öğrenme korelasyon katsayısı ve karekök ortalama hata kareleri değerleri kriter olarak alınmış ve karşılaştırılmıştır.

LGS Fen Bilimleri Alt Testinde sorulan 20 sorudan yapılan doğru sayısının tahmin edilmesi için öğrencilerin 4., 5., 6., 7., 8. Sınıf Fen Bilimleri dersi yazılı sınavlarında almış oldukları puanlardan oluşan toplamda 29 bağımsız değişken girdi verileri olarak kullanılmıştır. Yapılan yazılımda ağ tipi: ileri kademeli geri yayılım, performans fonksiyonu: ortalama karesel hata, transfer fonksiyonu: logaritmik sigmoid, öğrenme fonksiyonu: levenberg-marquardt, katman sayısı:3, gizli katman sayısı:1 olarak belirlenmiştir. 540 deneme sonunda en iyi performansı veren ağ mimarisinin ikinci denemede elde edilen 24 gizli hücre sayısına sahip ağ olduğu tespit edilmiştir. Bu ağın değerlerinin toplam $R=0.8059$, doğrulama $R=0.7408$, test $R=0.7568$, doğrulama performansının 7.0282 ve karekök ortalama hata kareleri (RMSE) değerinin 2.3504 olduğu görülmüştür. Ağın ürettiği öğrenme verileri ile gerçek veriler arasında yüksek korelasyonel ilişki olduğu sonucuna ulaşılmıştır. Daha sonra başlangıçta tahmin verisi olarak ayrılan daha önceden ağın görmediği 182 öğrenci veri seti kullanılarak, denenen tüm ağ mimarilerinin tahmin performansları çıkarılmıştır. İkinci denemede elde edilen en iyi öğrenme performansını veren ağın tahmin değerleri ile gerçek değerleri arasındaki korelasyon katsayısı $R= 0.7506$ ile en yüksek sonuç olduğu tespit edilmiştir. Bu ağın tahmin performansı sonucunda, tahmin edilen doğru sayıları ile gerçek doğru sayıları arasındaki hata değerinin büyük bir çoğunluğunun ($N= 124$) [+2, -2] aralığında olduğu sonucuna ulaşılmıştır.

Tartışma

2005 yılından itibaren uygulamaya konulan tüm Fen Bilimleri dersi öğretim programlarında sarmal olarak düzenlenen içeriğin kademeli olarak üst sınıf seviyelerine katkı sağlayıp sağlamadığını görmek amacıyla birinci alt problemde belirtilen, öğrencilerin ilkokuldan itibaren 4., 5., 6., 7. ve 8. sınıf Fen Bilimleri dersi yazılı sınav başarıları ile LGS sınavı fen bilimleri alt testi başarıları arasındaki ilişki

düzyini belirlemek için Pearson Moment Çarpım Korelasyonu analizi yapılmıştır. Sonuç olarak, LGS Fen Bilimleri alt testindeki öğrenci başarıları ile 8. Sınıf Fen Bilimleri dersi yazılı sınav başarı puanları arasında yüksek ilişki ($r= 0.70$) olduğu belirlenmiştir. En düşük ilişkinin ise 4. Sınıf Fen Bilimleri yazılı sınav başarı puanları ($r= 0.57$) ile olduğu görülmüştür. Yapılan analizde 4. Sınıftan 7. Sınıfa kadar sınav notları ile LGS Fen Bilimleri alt testi başarısının arasında orta düzey ilişki, 8.sınıf düzeyinde yüksek düzey ilişki saptanmıştır.

Veriler incelendiğinde genellikle 4. sınıf sınav notlarının yüksek olduğu ve sınıf düzeyi arttıkça notların düştüğü görülmüştür. Nitekim sınıf düzeyinde yazılı sınav puanı ortalamalarına bakıldığında en yüksek 4. Sınıfta ($\bar{x} = 82.25$) görülmüştür. Alt problemle ilgili araştırmanın sonucu literatürle paralellik göstermektedir. Nitekim Bursal (2013) bir çalışmasında; öğrencilerin fen ve teknoloji dersini görmeye başladıkları 4. sınıftan 8. Sınıfa kadar olan başarı değişimini uzunlamasına, aynı örneklem üzerinde incelemiş ve öğrencilerin 4. ve 5. sınıflarda 70'in üzerinde notlar ile fen bilimleri dersinde başarı göstermelerine rağmen, sınıf düzeyi arttıkça notlarında bazı düşmelerin olduğunu tespit etmiştir. Bursal, fen ders notlarının 4-6. sınıf düzeylerindeki yakın değerlerine ve 6. sınıftan itibaren anlamlı düzeyde düşmesine karşılık, 7 ve 8. sınıf düzeylerindeki fen notlarının kendi aralarında anlamlı bir farklılık göstermediğini saptamıştır. Nas 2015 yılında yaptığı araştırmasında fen ve teknoloji dersi akademik başarısı ile diğer derslerin akademik başarıları arasındaki ilişkiyi incelemiş ve değişken olarak öğrencilerin yazılı sınav notlarını işe koşmuştur. Yazılı sınav ortalamalarını karşılaştırdığında 4. sınıf öğrencilerinin tüm derslerde 5., 6., 7. ve 8. sınıf öğrencilerinden daha başarılı olduğunu belirtmiştir. Diğer sınıf seviyelerinde ise, bu anlamda belirgin bir fark görememiştir. Bu durumda ilkokul ve ortaokul seviyesinde bir farkın anlamlı olduğunu, ortaokulda ise sınıf seviyeleri arasında, akademik başarı anlamında bir farklılık olmadığını ortaya koymuştur.

İkinci alt problemde LGS Fen Bilimleri alt testi başarısını; ortaokul Fen Bilimleri akademik başarısının yanına ilkokul akademik başarı verisinin de katılarak ne derecede tahmin ettiği sorusuna cevap aranan bu çalışmada yapay sinir ağı ile modelleme performansına bakılmıştır. Ülkemizde yapay sinir ağlarının eğitim-öğretim alanında kullanımı 2000'li yıllarda başlamıştır (Güneri ve Apaydın 2004; Ayık, Özdemir ve Yavuz 200); İbrahim ve Rusli 2007; Tosun 2007; Tepehan

2011; Çırak 2012; Şengür ve Tekin 2013; Özdemir 2014). Bu araştırmada yapay sinir ağı ile oluşturulan modelde değişken olarak öğrencilerin 4., 5., 6., 7. ve 8. sınıf Fen Bilimleri dersi yazılı sınav notları işe koşularak, LGS Fen Bilimleri alt testi başarısı yordanmıştır. Ülkemizde yapılan yapay sinir ağı araştırmalarının bir kısmının da TEOG (Şen, Uçar ve Delen, 2012), KPSS (Demir, 2015), PISA (Tepehan, 2011) gibi standart testler ile öğrencilerin yazılı sınav (Turhan, Kurt ve Engin, 2013) ve genel akademik başarı notlarını (Şengür ve Tekin, 2013) tahmin etmeye yönelik olduğu görülmektedir. Yurt içi ve dışında eğitim-öğretim alanında yapılan birçok çalışmada bilişsel süreç becerilerinin yanı sıra akademik başarıyı etkileyen farklı değişken türlerini de işe koşmuşlardır. Yine bu çalışmalar yapay sinir ağlarının tahmin performansı ile sınıflandırma ve regresyon performanslarının karşılaştırılmasını içermektedir (Çırak 2012; Tepehan 2011; Turhan, Kurt ve Engin 2013; Bahadır 2013; Demir, 2015; Karamouzis ve Vrettos, 2008; Oladokun, Adebajo ve Charles-Owaba, 2008; Guo 2010; Kardan, Sadeghi, Ghidary ve Sani, 2013; Oancea, Dragoescu ve Ciucu, 2013; Naser, Zaqout, Ghosh, Atallah ve Alajrami, 2015).

Bu araştırma da Fen Bilimleri dersi başarısını etkileyen diğer faktörlerin işe koşulamamasının sebebi; ortaokuldan mezun olan öğrencilerin geçmiş döneme ait verilerinin okulun e-okul sisteminde bulunamamasıdır. Sadece öğrencilerin geçmiş dönem ders not fişleri raporlanabilmektedir. Ancak yapay sinir ağı tahmin modeli oluşturulurken bağımsız değişken olarak yalnız öğrencilerin o dersten aldıkları yazılı sınav notlarının bulunması durumunda bile elde edilen ağ tahmin performansı ($r= 0.7506$) yüksek düzey ilişki ortaya koymuştur. Bu araştırmanın bulgularının, ilgili çalışmalarda ve yukarıda bahsedilen çalışmalar incelendiğinde o çalışmalarda elde edilen bulgularla örtüştüğünü göstermektedir.

Öneriler

Bu bölümde araştırmanın sonuçları bağlamında araştırmacılar ve uygulayıcılara yönelik önerilere yer verilmiştir.

Bu araştırmada Fen Bilimleri dersi başarısının yordanmasına yönelik yapay sinir ağları ile performans modelleme çalışması yapılmıştır. Ayrıca Fen Bilimleri dersinin başarısının yordanmasında diğer disiplinlerle ilişkisi de incelenerek yapay sinir ağı, sınıflandırma, ayırma analizi ve çok değişkenli doğrusal regresyon analizi

gibi farklı istatistiksel yöntemlerin performanslarının karşılaştırılmasına yönelik arařtırmalar yapılabilir.

Yine bu arařtırmada elde edilen sonuçlar Bursa ilindeki 24 ortaokuldan toplanan veriler ile yapılmıřtır. Bursa ilinde genelleme yapabilmek için tüm okullardan toplanacak LGS' ye giren öğrencilerin gemiř döneme ait sınav notlarının yanı sıra akademik başarıya etkisi olabileceđi düşünölen tutum, anne-baba eğitim düzeyi, sosyo-ekonomik düzey ve bilimsel süreç becerileri gibi deđişkenler ile demografik bilgiler, devamsızlık durumları işe koşularak, il geneli LGS tahmin performans modeli alıřmaları yapılabilir. Böylelikle öğrencilerin okuldaki performanslarıyla LGS de elde edebilecekleri tahmini sonuçları önceden tespit etme řansı yakalamalarına imkân verip, bu konuda öğrencilere rehberlik alıřmaları yapılması ve önceden tedbirler alarak öğrencilerin kendilerini geliřtirmelerine fırsat tanınması sağlanabilir.

Arařtırmanın kapsamı genişletilerek aynı öğrenci grubuna ait ilkokul, ortaokul ve ortaöğretim akademik başarı puanlarının Yükseköğretim Kurumları Sınavı (YKS) alt testlerini yordama gücüne bakılabilir. İlköğretim kademesindeki akademik başarı puanlarının YGS Alt Testindeki başarı puanları ile ilişkisi incelenerek; ilkokul, ortaokul ve ortaöğretim akademik başarı puanları ile LGS başarı puanlarının YKS alt testi ham puanlarını tahmin etmesine yönelik alıřmalar yapılabilir.

Eđitim-öğretim alanı sadece öğrenci akademik başarısının arařtırılması ile sınırlı deđildir. Eğitim literatüründe; ilgi, tutum, zekâ, memnuniyet, öz-benlik, öz-yeterlik, öz-saygı, tatmin, psikolojik rahatsızlık vb. pek ok psikolojik yapının tespit edilmesine veya yordanmasına ilişkin analiz alıřmaları ve arařtırmalar yapılmaktadır. Bu arařtırmalarda makine öğrenmesi ile yapay sinir ađlarının kullanılmasının yararlı sonuçlar ortaya koyabileceđi düşünölmelidir.

Milli Eğitim Bakanlığı'nın e-okul sistemi içinde yer alan veri tabanından oluşturulacak düzenlemeler ile elde edilecek veriler; daha büyük örneklemlerde geleceđe yönelik daha kapsamlı tahmin alıřmalarının yapılmasına imkân sağlayacaktır.

Kaynaklar

- Adhikari, R., & Agrawal, R. K. (2013). A combination of artificial neural network and random walk models for financial time series forecasting. *Neural Computing and Applications*, 24(6), 1441-1449. doi:10.1007/s00521-013-1386-y
- Ahn, B. S., Cho, S. S., & Kim, C. Y. (2000). The integrated methodology of rough set theory and artificial neural network for business failure prediction. *Expert Systems with Applications*, 18(2), 65-74. doi:10.1016/s0957-4174(99)00053-6
- Ahmann, J. S. & Glock, M. D. (1971). *Evaluating pupil growth: principles of tests and measurements*. Boston: Allyn and Bacon Inc.
- Aiken, L. R. (1971). *Psychological testing and assessment*. (2. Edition) Boston: Pearson Education Group.
- Akamca, G. Ö. ve Hamurcu, H. (2005). Çoklu zekâ kuramı tabanlı öğretmen öğrencilerin fen başarısı, tutumları ve hatırd tutma üzerindeki etkileri. *Hacettepe Üniversitesi Eğitim Fakültesi Dergisi*, 28, 178-187.
- Akgün, E. (2017). *Sınıf öğretmeni adaylarının fen ve teknoloji eğitimi ders başarılarının yapay sinir ağları ile modellenmesi* (Doktora Tezi). Dumlupınar Üniversitesi Eğitim Bilimleri Enstitüsü, Kütahya.
- Altınok, H. (2005). Cinsiyet ve başarı durumlarına göre ilköğretim 5. sınıf öğrencilerinin fen bilgisi dersine yönelik tutumları. *Eurasian Journal of Educational Research*, 17, 81-91.
- Anıl, D. (2009). Uluslararası öğrenci başarılarını değerlendirme programı (PISA)'nda Türkiye'deki öğrencilerin fen bilimleri başarılarını etkileyen faktörler. *Eğitim ve Bilim*, 34(152), 87-100.

- Arıcı, İ. (2007). *İlköğretim din kültürü ve ahlak bilgisi dersinde öğrenci başarısını etkileyen faktörler -Ankara örneği*, (Doktora tezi). Ankara Üniversitesi Eğitim Bilimleri Enstitüsü, Ankara.
- Atalay, M. (2015). *Zaman serilerinde yapay sinir ağları ve bulanık mantığa dayalı tahmin ve bir uygulama* (Doktora Tezi). İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Ateşoğlu, T. M. (2015). *Ortaokul öğrencilerinde fen dersi başarısını yordayan değişkenlerin incelenmesi* (Yüksek Lisans Tezi). Ankara Üniversitesi Eğitim Bilimleri Enstitüsü, Ankara.
- Atila, M., & Özeken, Ö. (2015). Temel eğitimden ortaöğretime geçiş sınavı: Fen bilimleri öğretmenleri ne düşünüyor? *Ondokuz Mayıs Üniversitesi Eğitim Fakültesi Dergisi*, 34(1), 124-140.
- Aydoğan, İ. ve Zırhlıoğlu, G. (2018). Öğrenci başarılarının yapay sinir ağları ile kestirilmesi. *YYÜ Eğitim Fakültesi Dergisi*, 15(1), 577-610, Erişim adresi: <http://dx.doi.org/10.23891/efdyyu.2018.80>
- Ayık, Y. Z., Özdemir, A. & Yavuz, U. (2007). Lise türü ve lise mezuniyet başarısının kazanılan fakülte ile ilişkisinin veri madenciliği tekniği ile analizi. *Atatürk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 10(2), 441-454.
- Baş, N. (2006). *Yapay sinir ağları yaklaşımı ve bir uygulama* (Yüksek Lisans Tezi). Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Başol, G., & Zabun, E. (2014). The predictors of success in Turkish High School Placement Exams: exam prep courses, perfectionism, parental attitudes and test anxiety. *Educational Sciences: Theory and Practice*, 14(1), 78-87.
- Baştürk, R. (2008). Fen ve teknoloji alanı öğretmen adaylarının kamu personeli seçme sınavı başarılarının yordanması. *İlköğretim Online*, 7, 323-332. <http://ilkogretim-online.org.tr/index.php/io>
- Baykul, Y. (2000). *Eğitimde ve psikolojide ölçme: Klasik test teorisi ve uygulaması*. Ankara: ÖSYM Yayınları.

- Büyüköztürk, Ş. (2010). *Sosyal bilimler için veri analizi el kitabı: İstatistik, araştırma deseni SPSS uygulamaları ve yorum* (11.Basım). Ankara: PegemA Yayınları.
- Carter, V., & Good, E (1973). *Dictionary of education*.4th Edition. New York: McGraw Hill Book Company
- Cevat, F. (2009). *Akarsularda seviye akış ilişkilerinin yapay zekâ metotları ile belirlenmesi* (Yüksek Lisans Tezi). Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Kayseri.
- Cura, T. (2004). *Karar verme aracı olarak yapay sinir ağları ve yapay sinir ağları ile portföy optimizasyonu* (Doktora tezi). İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Çırak, G. (2012). *Yükseköğretimde öğrenci başarılarının sınıflandırılmasında yapay sinir ağları ve lojistik regresyon yöntemlerinin kullanılması* (Yüksek Lisans Tezi). Ankara Üniversitesi Eğitim Bilimleri Enstitüsü, Ankara.
- Çırak, G. ve Çokluk, Ö. (2013). Yükseköğretimde öğrenci başarılarının sınıflandırılmasında yapay sinir ağları ve lojistik regresyon yöntemlerinin kullanılması. *Mediterranean Journal of Humanities*:2, 70-79. doi: 10.13114/MJH/201322471
- Çitil, M., İspir, E., Söğüt, Ö. ve Büyükkasap, E. (2006). Fen edebiyat fakültesi öğrencilerinin profilleri ve başarılarını etkilediğine inandıkları faktörler K.S.Ü örneği. *Erzincan Eğitim Fakültesi Dergisi*, 8(2), 69-81.
- DeBoer, G.E. (2000). Scientific literacy: Another look at its historical and contemporary meanings and its relationship to science education reform. *Journal of Research in Science Teaching*, 37(6), 582-601.
- Demir, M. (2015). Predicting pre-service classroom teachers' civil servant recruitment examination's educational sciences test scores using artificial neural networks. *Educational Sciences: Theory & Practice*, 5, 1169-1177.

- Demirceylan, S., (2012). *Erzurum'da doğalgaz tüketim miktarının yapay sinir ağı algoritması kullanılarak tahmin edilmesi* (Yüksek Lisans Tezi). Atatürk Üniversitesi Fen Bilimleri Enstitüsü, Erzurum.
- Demirtaş, H., ve Güneş, H. (2002). *Eğitim yönetimi ve denetimi sözlüğü*. İstanbul: Anı Yayınları.
- Dinç, E., Dere, İ. ve Koluman, S. (2014). Kademeler arası geçiş uygulamalarına yönelik görüşler ve deneyimler. *Adıyaman Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 2014(17), 397-423.
- Dindar, H. ve Taneri, A. (2011). MEB'in 1968, 1992, 2000 ve 2004 yıllarında geliştirdiği fen programlarının amaç, kavram ve etkinlik yönünden karşılaştırılması. *Tebliğler Dergisi*, 19(2), 363-378.
- Ekiz, D. (2001). *İlköğretimde fen bilimi öğretimi ve öğrenimi*. Trabzon: Derya Kitabevi.
- Elmas, Ç. (2011). *Yapay zeka uygulamaları*, Ankara: Seçkin Yayınevi.
- Ergin, Ö. ve Ünal, G. (2006). Buluş yoluyla fen öğretiminin öğrencilerin akademik başarılarına, öğrenme yaklaşımlarına ve tutumlarına etkisi. *Türk Fen Eğitimi Dergisi*, 3(1), 36-52.
- Flitman, A. M. (1997). Towards analysing student failures: Neural networks compared with regression analysis and multiple discriminant analysis. *Computers & Operations Research*, 24(4), 367-377.
- Gülleroğlu, D. (2005). *Üniversite öğrencilerinin akademik başarılarının yordanmasına ilişkin karşılaştırmalı bir araştırma* (Doktora Tezi). Ankara Üniversitesi Eğitim Bilimleri Enstitüsü, Ankara.
- Gürdal, A. (1997). Sınıf öğretmenliği öğrencilerinin fene karşı tutumları ve fen öğretiminde entegrasyonun önemi. *Marmara Üniversitesi Atatürk Eğitim Fakültesi Eğitim Bilimleri Dergisi*, 9, 237-253.
- Güneri, N. ve Apaydın, A. (2004). Öğrenci başarılarının sınıflandırılmasında lojistik regresyon analizi ve sinir ağları yaklaşımı. *Ticaret ve Turizm Eğitim Fakültesi Dergisi*, 1, 170-188.

- Güneş, F. (2010). Öğrencilerde ekran okuma ve ekranik düşünme. *Mustafa Kemal Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 7(14), 1-20.
- Güney, E., 2009. *Kavramsal radyo sistemlerinde yapay sinir ağına dayalı kanal seçme yöntemi tasarım* (Yüksek Lisans Tezi). İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- González, J. M. B., & DesJardins, S. L. (2002). Artificial neural networks: A new approach to predicting application behavior. *Research in Higher Education*, 43(2), 235-258.
- Gorr, W. L., Nagin, D., & Szczypula, J. (1994). Comparative study of artificial neural network and statistical models for predicting student grade point averages. *International Journal of Forecasting*, 10(1), 17-34.
- Hamzaçebi, C. (2011). *Yapay sinir ağları: Tahmin amaçlı kullanımı Matlab ve Neurosolutions uygulamalı*. Bursa: Ekin Yayınevi.
- Hanımoğlu, E., ve İnanç, B. Y. (2011). The analysis of the relation among test anxiety, perfectionism and the attitudes of parents of the secondary students who will pass placement test. *Journal of Çukurova University Institute of Social Sciences*, 20(1), 351-366.
- Haykin, S. (1998). *Neural networks: A comprehensive foundation*. New Jersey: Prentice Hall PTR.
- Haykin, S. (2009). *Neural networks and learning machines*. New Jersey: Prentice Hall PTR.
- Heaton, J. (2008). *Introduction to neural networks for C#*. Chesterfield: Heaton Research Inc.
- Howie, S. J., & Pietersen, J. J. (2001). Mathematics literacy of final year students: South African realities. *Studies in Educational Evaluation*, 27, 7-25.
- Hündür, T. (2018). *Fen bilimleri öğretmenleri ile 8. sınıf öğrencilerinin mevcut sınav sistemine (teog) yönelik görüşlerinin incelenmesi (Kars ili örneği)* (Yüksek Lisans Tezi). Kafkas Üniversitesi Fen Bilimleri Enstitüsü, Kars.

- Karasar, N. (2000). *Bilimsel araştırma yöntemi*. Ankara: Nobel Yayın Dağıtım.
- Kavak, N., Tufan, Y. ve Demirelli, H. (2006). Fen teknoloji okuryazarlığı ve informal fen eğitimi gazetelerin potansiyel rolü. *Gazi Üniversitesi Gazi Eğitim Fakültesi Dergisi* 26(3), 17-28.
- Kayapınar, E. (2006). *Ortaöğretim kurumları öğrenci seçme ve yerleştirme sınavı (OKS)'na hazırlanan ilköğretim 8. sınıf öğrencilerinin kaygı düzeylerinin incelenmesi (Afyonkarahisar İli Örneği)* (Yüksek Lisans Tezi). Afyon Kocatepe Üniversitesi Sosyal Bilimler Enstitüsü, Afyon.
- Kayıkçı, Ş. (2014). *Web sayfalarının yapay sinir ağları ile sınıflandırılması* (Doktora tezi). Marmara Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Kısa, S. S. (1996). *İzmir il merkezinde dershaneye devam eden lise son sınıf öğrencilerinin sınav kaygılarıyla ana-baba tutumları arasındaki ilişki* (Yüksek Lisans Tezi). Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü, İzmir.
- Koç, M. L., Balas, C.E. ve Arslan, A. (2004). Taş dolgu dalgakıranların yapay sinir ağları ile ön tasarımı. *İMO Teknik Dergi*, 15(4), 3351-3375.
- Main, R. G. (1993). Integrating motivation into the instructional design process. *Educational technology*. 33(12), 37-41.
- Masters, T. (1995). *Advanced algorithms for neural networks: a C++ sourcebook*. Newyork: Wiley.
- Milli Eğitim Bakanlığı. (1992). İlkokul haftalık ders çizelgesinin kabulü, *Tebliğler Dergisi*, 55(2366), 569.
- Milli Eğitim Bakanlığı. (1995). *İlköğretim okulu programı*. Ankara: MEB Yayınları
- Milli Eğitim Bakanlığı. (2000). İlköğretim okulu fen bilgisi dersi (4, 5, 6, 7 ve 8. sınıf) öğretim programı, *Tebliğler Dergisi*, 63(2518), 1000-1105.
- Milli Eğitim Bakanlığı. (2005). *İlköğretim fen ve teknoloji dersi (4 ve 5. sınıflar) öğretim programı*. Ankara: MEB Yayınları

- Milli Eğitim Bakanlığı. (2006). *İlköğretim fen ve teknoloji dersi (6, 7 ve 8. sınıflar) öğretim programı*. Ankara: Talim Terbiye Kurulu Başkanlığı Yayını.
- Milli Eğitim Bakanlığı. (2013). *İlköğretim kurumları (ilkokullar ve ortaokullar) fen bilimleri dersi (3,4,5,6,7 ve 8. sınıflar) öğretim programı*. Ankara: Talim Terbiye Kurulu Başkanlığı Yayını.
- Milli Eğitim Bakanlığı. (2017a). *Fen bilimleri dersi (ilkokul ve ortaokul 3, 4, 5, 6, 7 ve 8. sınıflar) taslak öğretim programı*, Ankara: Talim ve Terbiye Kurulu Başkanlığı Yayını.
- Milli Eğitim Bakanlığı. (2017b). Müfredatta yenileme ve değişiklik çalışmalarımız üzerine..., basın açıklaması. Ankara: Talim ve Terbiye Kurulu Başkanlığı Yayını.
- Milli Eğitim Bakanlığı. (2018). *İlköğretim kurumları (ilkokullar ve ortaokullar) fen bilimleri dersi (3,4,5,6,7 ve 8. sınıflar) öğretim programı*. Ankara: Talim Terbiye Kurulu Başkanlığı Yayını.
- Memduhoğlu, H.B., ve Tanhan, F. (2013). Üniversite öğrencilerinin akademik başarılarını etkileyen örgütsel faktörler ölçeğinin geçerlik ve güvenilirlik çalışması. *Yüzüncü Yıl Üniversitesi Eğitim Fakültesi Dergisi*, 10(1), 106-124.
- 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(1), 42-71.
- Ocak, G., Akgül, A ve Yıldız, S.Ş. (2010). İlköğretim öğrencilerinin ortaöğretime geçiş sistemi'ne (OGES) yönelik görüşleri (Afyonkarahisar Örneği). *Ahi Evran Üniversitesi Kırşehir Eğitim Fakültesi Dergisi*, 11(1), 37-55.
- Oladokun, V.O., Adebajo, A.T. & Charles-Owaba, O.E. (2008). Predicting students' academic performance using artificial neural network: A case study of an engineering course. *The Pacific Journal of Science and Technology* 9(1), 72-79.
- Özgüven, İ. E. (1998). *Bireyi tanıma teknikleri*. Ankara: PDREM Yayınları.

- Özgüven, İ. E. (2002). *Psikolojik testler*. Ankara: Nobel Yayın Dağıtım.
- Özçelik, D. A. (1998). *Ölçme ve değerlendirme* (3. Baskı). Ankara: ÖSYM Yayınları.
- Özçelik, D. A. (2010). *Eğitim programları ve öğretim: (genel öğretim yöntemi)*. Ankara: Pegem Akademi.
- Özdemir, A. (2014). *İlköğretim ve ortaöğretim başarı ölçülerinin yükseköğretime geçiş sınav puanlarını yordama gücü* (Yüksek Lisans Tezi). Hacettepe Üniversitesi Eğitim Bilimleri Enstitüsü, Ankara.
- Özdemir, İ (2015). *Fen ve teknoloji öğretmenlerinin mesleki tükenmişliğini etkileyen değişkenlerin yapay sinir ağı ile öngörüsü* (Zonguldak İli Örneği) (Doktora Tezi). Ahi Evran Üniversitesi Fen Bilimleri Enstitüsü, Kırşehir.
- Özkan, M. ve Özdemir, EB. (2014). Ortaokul 8. sınıf öğrencilerinin ve öğretmenlerinin ortaöğretime geçişte uygulanan merkezi ortak sınavlara ilişkin görüşleri. *Tarih Okulu Dergisi* 7(10), 441-453.
- Öztemel, E. (2012). *Yapay sinir ağları*. İstanbul: Papatya Yayıncılık.
- Programme for International Student Assessment, (2015). MEB uluslararası öğrenci değerlendirme programı PISA 2015 ulusal raporu. Erişim Adresi: <http://pisa.meb.gov.tr/>
- Sarıer, Y. (2016). Türkiye’de öğrencilerin akademik başarısını etkileyen faktörler: Bir meta-analiz çalışması. *Hacettepe Üniversitesi Eğitim Fakültesi Dergisi*, 31(3), 1-20. doi:10.16986/Huje.2016015868
- Sağlam Tosun, N. (2016). *8. sınıf öğrencilerinin fen ve teknoloji ders başarısını etkileyen bazı faktörlerin incelenmesi* (Yüksek Lisans Tezi). Necmettin Erbakan Üniversitesi Eğitim Bilimleri Enstitüsü, Konya.
- Sönmez, V. (2010). *Program geliştirmede öğretmen el kitabı* (16. Baskı). Ankara: Anı Yayıncılık.

- Sünbül, A. M. ve Gürsel, N. (2001). Başarılı ve başarısız lise 1. sınıf öğrencilerinin öğrenilmiş çaresizlik ve problem çözme becerilerinin karşılaştırılması. *Selçuk Üniversitesi Eğitim Fakültesi Sosyal Bilimler Dergisi*, 12, 12-28.
- Şevik, Y. (2014). *İlköğretim müdür ve müdür yardımcılarının öğrencilerin akademik başarısını etkileyen faktörlere ilişkin görüşleri ile akademik başarısına katkıları* (Yüksek Lisans Tezi). Mehmet Akif Üniversitesi Eğitim Bilimleri Enstitüsü, Burdur.
- Şişman, M., Acat, M. B., Aypay, A. ve Karadağ, E. (2011). *TIMSS 2007 ulusal fen raporu: 8. sınıflar*. Ankara: EARGED Yayınları.
- Tan, Ş. (2008). *Öğretimde ölçme ve değerlendirme*. Ankara: Pegem Akademi Yayınları.
- Taşdemir, T. ve Tay, B. (2007). Fen bilgisi öğretiminde öğrencilerin öğrenme stratejilerini kullanmalarının akademik başarıya etkileri. *Eğitim Fakültesi Dergisi*. 20(1), 173-187.
- Tepahan, T. (2011). *Türk öğrencilerinin Pisa başarılarının yordanmasında yapay sinir ağı ve lojistik regresyon modeli performanslarının karşılatırılması* (Doktora Tezi). Hacettepe Üniversitesi Sosyal Bilimler Enstitüsü, Ankara.
- Tok, T. N. (2010). *Etkili Öğretim İçin Yöntem ve Teknikler*. A. Doğanay (Ed.). Öğretim ilke ve yöntemleri içinde (s.161-237). Ankara: PegemA Yayıncılık.
- Tosun, Ö. (2007). *Sınıflandırmada yapay sinir ağları ve karar ağaçları karşılaştırması: Öğrenci başarıları üzerine bir uygulama* (Yüksek Lisans Tezi). İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Tuan, H.L, Chin, C.C. & Shieh, S.H. (2005). The development of a questionnaire to measure students' motivation towards science learning. *International Journal of Science Education*, 27(6), 639-654.
- Turhan, K., Kurt, B., & Engin, Y. Z. (2013). Estimation of student success with artificial neural networks. *Education and Science*, 38(170), 112-120.
- Turgut, M. F. ve Baykul, Y. (2012). *Eğitimde ölçme ve değerlendirme* (4. Baskı). Ankara: Pegem Akademi Yayıncılık.

- Wang, D. B. (2004). Family background factors and mathematics success: A comparison of Chinese and US students. *International Journal of Educational Research*, 41, 40-54.
- Yavuz, S. ve Deveci, M. (2012). İstatiksel normalizasyon tekniklerinin yapay sinir ağı performansına etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 40, 167-187.
- Yetkin, M. (2014). *Tanker şamandıra bağlama sistemlerinin yapay sinir ağı tekniğiyle optimizasyonu* (Yüksek Lisans Tezi). İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Yılmaz, Ö ve Tuncer, M. (2018). Sınıf öğretmenliği üçüncü sınıf öğrencilerinin akademik başarı durumlarının çeşitli değişkenlere göre değerlendirilmesi. *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 1(7), 481-493.
- Yurdakul, E. M. (2014). *Türkiye'de ithalatın gelişimi ve ithalatın yapay sinir ağı yöntemi ile tahmin edilebilirliğine yönelik bir analiz* (Doktora tezi). Adnan Menderes Üniversitesi Sosyal Bilimler Enstitüsü, Aydın.
- Yurtoğlu, H. (2005). *Yapay sinir ağı metodolojisi ile öngörü modellemesi: bazı makroekonomik değişkenler için Türkiye örneği* (Uzmanlık Tezi). Devlet Planlama Teşkilatı, Ankara.
- Zhang, G. (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting* 14 (1998), 35–62.
- Zinicola, D. (2003). Learning science through talk: A case study of middle school students engaged in collaborative group investigation, (Doktora Tezi). The State University of New Jersey, USA.

Ekler



T.C.
BURSA VALİLİĞİ
İl Millî Eğitim Müdürlüğü

Sayı : 86896125-605.01-E.7245299

10.04.2019

Konu : Ahmet ATASAYAR'ın Araştırma İzni

MÜDÜRLÜK MAKAMINA

İlgi : Millî Eğitim Bakanlığının Araştırma, Yarışma ve Sosyal Etkinlik İzinleri konulu 22/08/2017 tarihli ve 2017/25 sayılı Genelgesi.

Dumlupınar Üniversitesi Eğitim Bilimleri Enstitüsü Sınıf Eğitimi tezli yüksek lisans programı öğrencisi Ahmet ATASAYAR'ın "İlkokul 4. Sınıftan İtibaren Fen Bilimleri Derslerindeki Başarının Liselere Giriş Sınavı Fen Bilimleri Dersi Başarısını Yordamasının Yapay Sinir Ağları İle Modellenmesi" konulu tez çalışması Dumlupınar Üniversitesi Rektörlüğü Öğrenci İşleri Daire Başkanlığının 28/03/2019 tarihli 2262 sayılı yazıları ile bildirilmektedir.

Dumlupınar Üniversitesi Eğitim Bilimleri Enstitüsü Sınıf Eğitimi tezli yüksek lisans programı öğrencisi Ahmet ATASAYAR'ın "İlkokul 4. Sınıftan İtibaren Fen Bilimleri Derslerindeki Başarının Liselere Giriş Sınavı Fen Bilimleri Dersi Başarısını Yordamasının Yapay Sinir Ağları İle Modellenmesi" konulu tez çalışmasını ilimizde 2017-2018 Eğitim Öğretim yılında LGS sınavına giren ortaokul 8. Sınıf öğrencilerinin sınav sonuç raporları üzerinden yapma isteği ilimizde oluşturulan "Araştırma Değerlendirme Komisyonu" tarafından incelenerek değerlendirilmiştir. Araştırma ile ilgili çalışmanın ilgi Genelge çerçevesinde uygulanması ayrıca **araştırma sonuçlarının Müdürlüğümüz ile paylaşılması** komisyonumuzca uygun görülmektedir.

Makamlarınızca da uygun görülmesi halinde olurlarınıza arz ederim.

Ekrem KOZ
İl Millî Eğitim Müdür Yardımcısı

OLUR
10.04.2019

Sabahattin DÜLGER
İl Millî Eğitim Müdürü

Adres : Hocahasan Mh. İlbahar Cad. No:38
(Yeni Hükümet Konağı A Blok) 16050/Osmangazi/BURSA
Telefon No:(0224)445 16 00 Fax: 445 18 10
E-posta: arge16@meb.gov.tr İnternet Adresi: http://bursa.meb.gov.tr

Bilgi İçin : Engin SEYMEN
AR-GE VHKİ
(0224) 215 25 39

Bu evrak güvenli elektronik imza ile imzalanmıştır. <https://evraksorgu.meb.gov.tr> adresinden de15-2b80-3954-b820-084b kodu ile teyit edilebilir.

Özgeçmiş

Adı Soyadı : Ahmet ATASAYAR
Doğum Yeri ve Yılı : Kırıkkale - 1984
E-posta Adresi : ahmetatasayar06@gmail.com

Öğr. Gördüğü Kurumlar:	Başlama	Bitirme	Kurum Adı
Lise	1998	2002	Atatürk Anadolu Lisesi
Lisans	2002	2006	Gazi Üniversitesi
Yüksek Lisans	2012	2019	Dumlupınar Üniversitesi

Bildiği Yabancı Diller ve Düzeyi : İngilizce - Orta

Çalıştığı Kurumlar:

Başlama ve Ayrılma	Kurum Adı	Statü
1.2006-2011	Adaköy Ateş Sarıbal İlköğretim Okulu	Öğretmen
2.2011-2014	Hamdi Çalış İlköğretim Okulu	Öğretmen
3.2014-2016	Mehmet Akif Ersoy İlkokulu	Öğretmen
4.2016-2017	Uludağ İlkokulu	Müdür Yrd.
5.2017-	Bursa İl Milli Eğitim Müdürlüğü	Ar-Ge Personeli

Yurt İçi ve Yurt Dışında Katıldığı Projeler:

1. Amigurumi ile Stop Motion Animasyon (2013)
(Gençlik Spor Bakanlığı Gençlik Projesi Proje Koordinatörü)
2. Masallar Canlanıyor (2017)
(BEBKA-Bursa Millî Eğitim Müdürlüğü)
3. Temel Algoritma ve Kodlama Projesi (2018)
(Bursa İl Milli Eğitim Müdürlüğü Proje Koordinatörü)
4. Youth Online (2018)
(Erasmus Plus KA2 Projesi, Helsinki)
5. AR/VR Destekli Eğitsel Dijital İçerik Geliştirme (2018)
(BEBKA-Bursa İl Milli Eğitim Müdürlüğü Proje Koordinatörü)
6. Bursa Veri-M Hareketi Projesi (2019)
(Bursa İl Milli Eğitim Müdürlüğü Proje Koordinatörü)

