

Fen Bilgisi Öğretmen Adaylarının Genel Not Ortalamalarının Sınıflandırılmasında Yapay Sinir Ağlarının Kullanımı *

The Use of Artificial Neural Networks in Classifying the Average Grade of Science Teachers' Candidates

Nesibe YORGANCI **
Dr. Öğr. Üyesi, Nimet IŞIK ***

Öz:

Yapay sinir ağları (YSA) ekonomi, tıp, turizm, mühendislik ve sanayi gibi alanlarda sıklıkla kullanılmaktadır. Eğitim alanında kullanımının ise son yıllarda artış gösterdiği görülmüştür. Bu nedenle yapılan bu çalışmada öğrenci başarısını etkileyebileceği düşünülen değişkenlerden baskın zekâ alanları, çalışma alışkanlıkları, cinsiyet ve yaş değişkenleri ile öğrencilerin genel not ortalamalarına göre sınıflandırılmasında YSA'nın kullanımı amaçlanmıştır.

Araştırmada öğrencilerin sahip oldukları çalışma alışkanlıkları, baskın zekâ alanları ve yaş gibi değişkenleri ile genel not ortalamalarına göre sınıflandırılmasında yapay sinir ağı modeli kullanılmıştır. Araştırmanın örneklemini eğitim fakültesi Fen Bilgisi Öğretmenliği bölümünde lisans öğrenimi gören 30 dördüncü sınıf öğretmen adayı oluşturmaktadır. Çalışmada üç adet veri toplama aracı kullanılmıştır. İlk olarak adayların yaş, cinsiyet ve genel not ortalamalarının belirlenmesini sağlayan demografik ölçek, ikinci olarak sahip olunan çalışma alışkanlıklarını belirleyebilecek 60 maddeden oluşan bir çalışma alışkanlıkları envanteri

*Bu çalışma 4th International Eurasian Educational Research Congress Denizli, 11-14 May 2017'de bildiri olarak sunulmuştur.

**Mehmet Akif Ersoy Üniversitesi Matematik ve Fen Bilimleri Eğitimi Bölümü, Burdur/TURKEY, nesibeyorganci@gmail.com, ORCID ID: 0000-0002-3667-3210

*** Mehmet Akif Ersoy Üniversitesi Matematik ve Fen Bilimleri Eğitimi Bölümü, Burdur/TURKEY, nokumus@mehmetakif.edu.tr, ORCID ID: 0000-0002-1347-6628

kullanılmıştır. Ayrıca adayların baskın zekâ alanlarını belirlemek için de Gardner tarafından hazırlanan 80 maddelik çoklu zekâ envanteri verilerin toplanmasında kullanılan araçlardır. Çalışmada elde edilen veriler bilgisayar ortamına aktarılarak Matlab R2012a programıyla analize hazır hale getirilmiştir. Hazırlanan veriler ise YSA modellerinden Çok Katmanlı Algılayıcı ağ modeli yardımıyla analiz edilmiştir.

Yapay sinir ağı modellerinden çok katmanlı algılayıcı ağ modelinin kullanıldığı bu çalışmada 142 giriş verisi ve 9 çıkış verisiyle oluşturulan ağ yapıları incelenmiştir. Burada amaç, ağın oluşturması beklenen veri ile araştırmacı tarafından ağa sunulan çıkış verisi arasında en az hatanın yapıldığı ağın bulunmasını sağlamaktır. Sonuçlara göre en az hata gizli katmanda 25 nöron bulunduran ağda meydana gelmiştir. Bu yapının hata kareler ortalamalarına bakıldığında eğitim veri seti için 0.03, geçerlilik veri seti için 0.004 ve test veri seti için de 0.005 olduğu görülmektedir.

Sonuç olarak öğrencilerin yaş, cinsiyet, baskın zekâ alanları ve sahip oldukları çalışma alışkanlıkları ile genel not ortalamaları YSA modellerinden çok katmanlı algılayıcı ağ modeli yardımıyla sınıflandırılabilir. Elde edilen hata kareler ortalamaları, kullanılan değişkenler ve örneklem sayısına göre farklılık gösterebileceğinden dolayı çalışmanın farklı gruplar üzerinde farklı değişkenlerle yinelenmesi tavsiye edilmektedir.

Anahtar sözcükler: Yapay Sinir Ağları, Çok Katmanlı Algılayıcı Model, Sınıflandırma, Çalışma Alışkanlıkları ve Genel Not Ortalamaları.

Abstract:

The aim of this research is to evaluate the use of artificial neural networks to classify multiple intelligence areas, working habits, age and gender variables and students' grade averages from variables thought to affect students' success.

In the study, an artificial neural network model was used to classify students' achievements. The group consists of 30 students who were in their 4th year in the 2016-2017 academic year. The group were students of Mehmet Akif Ersoy University in the department of science teacher. In the study, three data collection tools were used. First the demographic scale that evaluates a candidate's age, gender and general grade point average. Second the study habits' inventory which allows the evaluation of the working habits. And finally, a multiple intelligence inventory to identify the dominant intelligence' areas. The collected data was computerized and prepared for analysis by a Matlab R2012a program. The prepared data was analyzed with the multilayer perceptron model from the artificial neural network models.

In this study, which is a multi-layered perceptron network model from artificial neural network models, network structures formed by 142 input data and 9 output data, are examined. The aim is to find the network the least error is made between the data that is expected to form the network and the output data provided to the network by the researcher. According to the results, the least error occurred in the mesh containing 25 neurons in the hidden layer. When we look at the average of error squares, the results show 0.03 for education data set, 0.004 for validity data set, and 0.005 for test data set.

As a result, students' achievement can be classified by the artificial neural network model. In the study, the mean square error can be measured according to the used variables and the number of samples. For this reason, it is recommended that the study may be repeated in different samples with different variables.¹

Keywords: Artificial Neural Networks, Multilayer Perceptron Model, Classification, Study Habits and General Grade Point Averages.

Giriş:

Başarı, bireyin sahip olduğu yetenek ve yetişmesine bağlı sergilediği fiili davranışların olumlu sonucudur (Bilim ve Sanat Terimleri Ana Sözlüğü). Eğitimde başarı, birçok birey ve kurum için öncelikli hedefler içerisinde yer almaktadır. Bu hedefe ulaşma yolunda karşılaşılan engellerin çözümü için öncelikle problemin kaynağı bulunmalıdır. Bireyin başarısızlık nedenlerinin bilinmesi, bu problemin çözümü için atılacak önemli adımlardan biridir (Atılğan 1998: 2). Bunun yanı sıra bireylerin başarı durumlarına göre sınıflandırılmaları, ihtiyaçları doğrultusunda onlara sunulacak eğitimin niteliğini de artıracaktır (Çıracak ve Çokluk 2013).

Eğitimde bireyin başarısını etkilediği düşünülen birçok değişken vardır. Ailenin eğitim düzeyi, öğrencinin sahip olduğu imkânlar ve öğrencinin ders çalışmaya ayırdığı vakit bu değişkenlerdendir (Özer ve Anıl 2011). Okula başlama yaşı, cinsiyet (Gürsakal 2012), zekâ alanları ve öğrenme stilleri (Snyder 2000: 19), sosyo-ekonomik durumları (Şirin 2005) ve bireylerin sahip oldukları verimli ders çalışma alışkanlıkları (Atılğan 1998) gibi değişkenler öğrenci başarısını etkileyebilmektedir. Bireyin başarısını etkileyen değişkenler ile başarı arasındaki ilişkinin bilinmesi ve daha önceden tahmin edilip sınıflandırılabilir olması, birçok eğitim uygulamasında oldukça yarar sağlayabilecektir. Yapılan çalışmalar bu değişkenlerin bireyin başarısında ne ölçüde etkili olduğunu göstermektedir.

Başarıyı etkileyen değişkenler ve başarı arasında kurulacak ilişki çoğu zaman doğrusal bir model şeklinde değildir. Araştırma sonuçları, sayıltı olarak kabul edilen birçok çevresel değişken tarafından etkilenmektedir. Bu etkinin olumsuz sonuçlarının mümkün olduğunca azaltılabilmesinde, kullanılan istatistiksel yöntemin payı oldukça fazladır. Bu nedenle araştırmada kullanılan analiz yönteminin iyi bir şekilde seçilmiş olması gerekmektedir. Teknolojinin hızla geliştiği mevcut bilişim çağında, sosyal ve beşeri bilimler alanında yapılan çalışmalarda değişken miktarlarının ve özelliklerinin artmasıyla belli bir sonuca ulaşmak araştırmacılar açısından bir miktar zorlayıcı olabilmektedir. Bu zorlukların aşılmasında etkili çalışan araştırma arkadaşları, araştırmacıya kolaylık sağlayabilecektir. Bu noktada ise yapay zekâ çeşitlerinden biri olan yapay sinir ağları (YSA) ile tanışmaktayız. Sonucu etkileyebilecek çevresel faktörler arttıkça, değişkenler hakkında tahmin veya sınıflandırma yapmak insan beyni için biraz daha karmaşık hale gelebilmektedir. Ancak çeşitli algoritmalar yardımıyla çalışan yapay sinir ağlarında sınıflandırma ve tahmin yapmak kolaylaşmaktadır.

Biyolojik bir sistem olan insan, çevreden aldığı uyarıyı nöronlar yardımıyla beyne iletir. Beyin ise kendisine ulaşan bu uyarılar için bir cevap hazırlayarak yine nöronlar aracılığıyla hedef organa cevabını ulaştırır (Bailey 2017). İnsan vücudunda oldukça karmaşık olan bu verilerin iletimi ve işlenmesi sürecini basit olarak böyle açıklayabiliriz. Teknolojiyle birlikte hayatımıza giren yapay sinir ağı kavramı, insan beyin yapısının elektronik olarak modellenmesi olarak tanımlanabilir (Anderson ve McNeill 1992). Bu kavram için Elmas genel bir ifadeyle, insan beyninin çalışmasını taklit eden bilgisayar sistemleri olduğunu söylemiştir (Elmas 2016).

Öztemel'e göre ise YSA, eğitim veri setlerinden, olaylar arasındaki ilişkileri öğrenerek hiç görmediği örnekler hakkında öğrendikleri bilgileri kullanarak karar veren sistemlerdir. (Öztemel 2016: 27).

Yapay zekânın alt dallarından biri olan yapay sinir ağlarını sayısal bilgisayarların çalışmasından ayıran en önemli özelliği, insana özgü olan örnekler aracılığıyla öğrenmeyi gerçekleştirebiliyor olmasıdır. Yapay sinir ağı teknolojisi, öğrenebilen sistemlerin temelini oluşturmaktadır. Biyolojik sistemlere ait olan yaşayarak öğrenme yeteneği, bu teknoloji sayesinde bilgisayar ortamında kullanılabilir. Sisteme girdi verilerinden öğrenmeyi gerçekleştiren YSA, birçok avantaj sunmaktadır. Bu avantajların başında doğrusal olmayan yapıya sahip olması (Russell ve Norvig 2010: 732), değişkenler arasındaki olası etkileşimleri saptayabilmesi, eğitimi için farklı algoritmalarla geliştirilebiliyor olması (Tu 1996: 1229), öğrenebilirliği, eksik bilgi ile çalışabilmesi, hata toleransına sahip olması, genelleme yapabilmesi gibi özellikler gelmektedir (Öztemel 2016). YSA insan beynini makine üzerinde taklit etmek için geliştirilmiş bir model olmasına rağmen, veriler hakkında herhangi bir bilgi veya varsayım olmadan, belirli bir veri setinin girdi ve çıktıları arasındaki ilişkiyi çok iyi bir şekilde öğrenme yeteneğine sahiptir (Kamruzzaman, Sarker ve Begg 2006: 2). Sahip olduğu bu yetenek sayesinde yapay sinir ağına, olaylara ait örnekler verilerek ağın eğitimi sağlanır. Eğitilen ağ böylelikle bazı genellemeler yapabilir duruma gelir. Öğrenmesi gerçekleşen sinir ağı, henüz karşılaşılmamış olaylara bu örnekler ve eğitim sayesinde çözüm üretebilir.

YSA'nın çeşitli problem durumlarına uygun olarak kullanılan farklı modelleri bulunmaktadır. Çok katmanlı algılayıcı (ÇKA), doğrusal vektör parçalama modeli (LVQ), adaptif rezonans teori (ART) ağları bu modellerden bazılarıdır. Bu çalışmada da kullanılan modellerden biri olan ÇKA ağ modeli temelde üç katmandan oluşmaktadır. Bunlar girdi katmanı, gizli katman da dediğimiz ara katmanlar ve çıktı katmanıdır (Öztemel 2016). Girdi ve çıktı katmanındaki elemanların sayısı problem durumundaki değişkenlere göre araştırmacı tarafından belirlenmektedir. Gizli katman nöron sayısı, ağın eğitimi süresince en iyi sonuç elde edilene kadar değiştirilmektedir.

ÇKA ağ modelinin eğitim felsefesinde, ağın belli bir girdi örneği için bir çıktı verisi oluşturması beklenir. Ağ tarafından oluşturulan çıktı ve ağdan üretmesi beklenen çıktı arasındaki fark, ağın performansını belirtmektedir. Bu iki çıktı veri arasındaki fark, hata olarak kabul edilir. Ağın iyi bir performansına sahip olması için bu farkın olabildiğince az olması gerekmektedir (Öztemel 2016). En uygun sonucu alana kadar, ağın sahip olduğu ağırlıklar ve gizli katman nöron sayıları değiştirilerek ideal hata değerine ulaşılması sağlanır.

Makine öğrenmesi sağlayan ve biyolojik sinir hücrelerini taklit eden yapay sinir ağları ilişkilendirme, sınıflandırma, genelleme, öngörü gibi konularda başarılı bir şekilde uygulanmaktadır (Öztemel 2016). Yapay sinir ağlarının ilk olarak ortaya çıkışı her ne kadar 1940lı yıllara dayansa da, daha yaygın bir şekilde kullanımı bizlere yakın bir geçmişi işaret etmektedir. Uygulama alanları olarak bakıldığında

ise çevresel sorunlara karşı erken uyarılarda (Moustris, Nastos, Larissi ve Paliatos 2012), tıp (Ergün, Serhatlıoğlu, Hardalaç ve Güler 2004), mühendislik (Fırat ve Güngör 2004) ve ekonomi (Yurtoğlu 2005) gibi alanlarda uygulandığı görülmüştür. Bilgisayar teknolojilerinin artmasıyla birlikte yapay sinir ağları, özellikle eğitim alanında da etkili bir şekilde kullanılmaya başlanmıştır. Öğrencilerin başarısız olma nedenlerinin analizinde, çeşitli değişkenlere göre mezuniyet durumlarının ve akademik performanslarının öngörülmesinde ve sınıflandırılmasında yapay sinir ağları kullanılmaktadır (Bahadır ve Özdemir 2016).

İlgili alan yazın incelendiğinde YSA'nın eğitim alanında kullanımı ile ilgili bazı çalışmalar dikkat çekmektedir. Bunlardan bazılarını şu şekilde ifade edebiliriz. Oladokun, V. O., Adebajo, A. T. & Charles-Owaba, O.E., "Predicting Students' Academic Performance Using Artificial Neural Network: A Case Study of an Engineering Course" isimli çalışmalarında, Nijerya'nın ilk üniversitesi olan, Ibadan Üniversitesi Mühendislik Fakültesi bölümündeki öğrencilerin akademik başarılarını YSA kullanarak belirli değişkenler yardımıyla tahmin etmeye çalışmışlardır. Bu çalışma için geliştirdikleri Multilayer Perceptron Topology (Çok Katmanlı Algılayıcı Modeli) sayesinde olası öğrenci performanslarını %70 oranında doğrulukla tahmin ettiği görülmektedir (Oladokun, Adebajo ve Charles-Owaba 2008). Wongkhamdi, T. & Seresangtakul, P., "A Comparison of Classical Discriminant Analysis and Artificial Neural Networks in Predicting Student Graduation Outcomes" isimli çalışmalarında 594 öğrenci profili örneği kullanarak öğrencilerin mezuniyet durumlarının tahmininde klasik diskriminant analizi ile yapay sinir ağlarının performanslarını karşılaştırmalı olarak sunmuşlardır. Modelin gücü classification correct rate (CCR) ile ölçülmüş ve yapay sinir ağlarının ortalaması klasik diskriminant analizine göre daha yüksek çıkmıştır. Sırasıyla en iyi verim yapay sinir ağlarında %93.3, diskriminant analizinde ise %81.5 şeklinde ölçülmüştür (Wongkhamdi ve Seresangtakul 2010). Howell, R. M. & Fowler, D., "A Neural Network as an Instrument of Prediction" isimli çalışmalarında diş hekimliği fakültesi öğrencilerine ait yaş, ağırlıklı not ortalaması, akademik saatler gibi verileri giriş verisi olarak kullanmışlar ve YSA modeli yardımıyla öğrencilerin mezun olup olamayacaklarına dair tahminde bulunmuşlardır. Elde ettikleri sonuçlar doğrultusunda YSA ile yapılan mezuniyet başarı tahmininde oldukça doğru sonuçlara ulaştıklarını belirtmişlerdir (Howell ve Fowler 1990). İbrahim, Z. & Rusli, D., "Predicting Students' Academic Performance: Comparing Artificial Neural Network, Decision Tree and Linear Regression" isimli çalışmalarında öğrencilerin demografik profilleri ve kümülatif not ortalamalarını kullanarak akademik başarı tahmini yapmışlardır. Bu başarı tahmininde YSA, Karar Ağaçları (KA) ve Lineer Regresyon (LR)' un tahmin doğruluklarını karşılaştırmışlardır. Her üç teknik de %80'in üzerinde başarı göstermesine rağmen YSA diğer iki yöntemden çok daha iyi performans göstermiştir (İbrahim ve Rusli 2007). Bahadır, E., "Yapay Sinir Ağları Ve Lojistik Regresyon Analizi Yaklaşımları İle Öğretmen Adaylarının Akademik Başarılarının Tahmini" adlı doktora tezinde farklı sektörlerde de etkili bir öngörü metodu olarak yararlanan YSA'yı kullanmıştır. Bu çalışmasında öğrenci

başarılarını tahmin etme amacıyla, yenilikçi bir yöntem olan YSA'yı kullanarak etkili bir öngörü yapabilmeyi amaç edinmiştir. Aynı zamanda bu tahmini, aynı değişkenleri kullanarak Lojistik Regresyon Analizi (LRA) ile yapıp, her iki yöntemin başarı durumlarını karşılaştırmıştır. Marmara Üniversitesi Atatürk Eğitim Fakültesinde okuyan ve mezun olan 139 öğrenci ile yaptığı çalışmada YSA ile yapılan başarı **öngörüsünün LRA ile yapılan başarı öngörüsüne göre daha net sonuçlar verdiği görülmüştür** (Bahadır 2013).

YSA'nın tahmin ve öngörü amacıyla kullanıldığı bu çalışmaların yanı sıra sınıflandırma amaçlı kullanımında (Çırak ve Çokluk 2013) tarafından gerçekleştirilen çalışma dikkat çekmektedir. "Yükseköğretimde Öğrenci Başarılarının Sınıflandırılmasında Yapay Sinir Ağları ve Lojistik Regresyon Yöntemlerinin Kullanılması" adlı çalışmalarında, kendi geliştirdikleri "Üniversite Öğrencilerinin Akademik Başarılarını Etkileyen Değişkenler Anketini" kullanmışlardır. Elde edilen veriler doğrultusunda farklı fakülte ve programlara kayıt yaptıran öğrencilerin, olası başarılarının tahminine imkân sağlayacak sınıflandırma modelleri olarak, YSA ve LRA performansları karşılaştırılmıştır. Çalışma sonucunda öğrencilerin başarılı ve başarısız olarak sınıflandırılmasında YSA'nın LRA'ya göre daha yüksek doğru sınıflandırma yaptığı görülmüştür (Çırak ve Çokluk 2013).

a. Araştırmanın Amacı ve Önemi

Yapılan literatür taramasında da görüldüğü üzere YSA, sınıflandırma ve tahmin gibi amaçlarla kullanıldığında oldukça başarılı sonuçlar verebilmiştir. Her ne kadar ekonomi, tıp, turizm, mühendislik ve sanayi gibi alanlarda kullanılıyor olsa da YSA'nın eğitim alanındaki uygulamaları son yıllarda artış göstermektedir. Ancak bu uygulamalar çoğunlukla tahmin amaçlı yapılan çalışmalar olmuştur. YSA'nın sınıflandırma alanında da başarılı sonuçlar verebileceği düşünüldüğünde farklı değişkenler kullanılarak yapılacak çalışmalar alana katkıda bulunabilecektir. Bu nedenle öğrencilerin çalışma alışkanlıkları, baskın zekâ alanları ve yaş değişkenlerine göre genel not ortalamalarının sınıflandırılmasında YSA kullanımının iyi bir sonuç oluşturabileceği düşüncesiyle bu çalışma yapılmıştır. Yapılan bu araştırmanın temelinde, öğrenci başarısını etkileyebileceği düşünülen değişkenlerden yaş, cinsiyet, baskın zekâ alanı ve çalışma alışkanlıkları ile öğrencilerin ağırlıklı genel not ortalamalarına göre sınıflandırılmasında yapay sinir ağı modellerinden çok katmanlı algılayıcı ağ modelinin kullanılabilirliğinin tespit edilmesi amaçlanmıştır. Bu bağlamda çalışmada cevaplanmaya çalışılan soru şu şekildedir:

Yapay sinir ağı modellerinden çok katmanlı algılayıcı ağ modeli, baskın zeka alanı ve çalışma alışkanlıklarına göre, öğrenci başarılarını sınıflandırmada kullanılabilecek etkili bir yöntem midir?

Yöntem:

a. Araştırma Deseni

Araştırmada öğrencilerin sahip oldukları çalışma alışkanlıkları, baskın zekâ alanları, yaş ve cinsiyet gibi değişkenleri ile genel not ortalamalarına göre sınıflandırılması amaçlandığı için nicel araştırma yöntemlerinden yapay sinir ağı modeli kullanılmıştır.

b. Araştırma Grubu

Araştırma, 2016-2017 Eğitim- Öğretim yılında Mehmet Akif Ersoy Üniversitesi Eğitim Fakültesi Fen Bilgisi Öğretmenliği bölümünde öğrenim gören 30 dördüncü sınıf lisans öğrencisi ile gerçekleştirilmiştir. Araştırma grubu seçilirken zaman ve iş gücü kaybını önlemek amacıyla uygun örnekleme yöntemi seçilmiştir. Araştırma grubunun 18'i (%60) kadın, 12'si (%40) erkek öğrenciden oluşmaktadır. Araştırma grubunda katılımcılardan 20 kişi 20-22 yaş aralığında, 8 kişi 23-25 yaş aralığında bulunmaktadır. 2 katılımcı da 26 ve üstü yaşa sahiptir.

c. Veri Toplama Aracı

Çalışmada öğrencilerin yaş, cinsiyet ve genel not ortalamalarını içeren bir “*demografik ölçek*”, çalışma alışkanlıklarını belirleyen 60 maddelik bir “*çalışma alışkanlıkları envanteri*” ve öğrencilerin sahip oldukları baskın zekâ alanlarını belirleyebilmek için 80 maddelik “*çoklu zekâ envanteri*” veri toplama aracı olarak kullanılmıştır. Demografik ölçekte yer alan değişkenler araştırmacılar tarafından belirlenmiştir. Ölçekte yer alan yaş ve cinsiyet özellikleri girdi veri olarak yapay sinir ağına sunulurken, genel not ortalaması çıktı veri olarak kullanılmıştır.

Çalışma alışkanlıkları envanteri ise 1981 yılında Uluğ tarafından geliştirilmiştir (Uluğ 1981; Aktaran: Kaya 2001). Katılımcılar bu envantere sahip oldukları alışkanlıklar için evet veya hayır şeklinde yanıt vermişlerdir. Testin güvenilirliği 16 kişilik deneme grubuna yapılan test-tekrar test uygulaması ile sağlanmış ve korelasyon katsayısı 0.79 olarak bulunmuştur. Bir sonraki uygulamada ise 38 kişilik bir başka grupta ön test- son test olarak uygulanmıştır. Bu uygulama sonucunda ise uygulanan envanter puanları arası korelasyon katsayısı 0.82 olarak belirlenmiştir (Uluğ 1981; Aktaran: Kaya 2001).

Bir diğer envanter ise Gardner tarafından geliştirilen ve Oral tarafından Türkçeye çevrilen çoklu zekâ envanteridir (Oral 2001). Envanterin Türkçe diline uyarlanmasında testin güvenilirliği, test yarılama yöntemi ile sağlanmıştır. Güvenirlik sonuçlarına bakıldığında ise testin iki formu arasındaki korelasyon değeri 0.79 olarak hesaplanmıştır (Oral 2001). Katılımcılar çoklu zekâ envanterinde maddeleri, kendilerine uygunluklarına göre 1'den 5'e kadar numaralandırmışlardır.

d. Veri Analizi

Elde edilen verilerin analizinde, nicel verilerle tahmin ve sınıflandırma amacıyla verimli bir şekilde kullanılan Yapay Sinir Ağları modellerinden Çok Katmanlı Algılayıcı (ÇKA) ağ modeli tercih edilmiştir (Bahadır 2013). Araştırmada öğrencilerin yaş, cinsiyet, çalışma alışkanlıkları ve baskın zekâ alanları giriş verileri olarak kullanılırken genel not ortalamaları ise çıkış verisi olarak kullanılmıştır. Yapay sinir ağları, girdi ve çıktı verileri arasında ilişki kurabilmektedir. Yapay sinir ağları uygun verilerle eğitildiği takdirde, daha önce ağın karşılaşmamış olduğu girdi verilerine karşı uygun çıktılar üretebilmektedir (Anderson ve McNeill 1992). Bu çalışma stratejisiyle, girdi verileri ve o girdi verilerine karşılık beklenen çıktılar ağa gösterilerek ağın eğitimi sağlanmıştır. Araştırmada katılımcılardan elde edilen veriler bilgisayar ortamına aktarılarak Matlab R2012a programında analize hazır hale getirilmiştir. Toplanan verilerden yaş, cinsiyet, baskın zekâ alanı ve sahip olunan çalışma alışkanlıkları toplamda 142 madde şeklinde giriş verisi olarak kullanılmıştır. Genel not ortalamaları için ise 49 ve aşağısı, 50-59, 60-64, 65-69, 70-74, 75-79, 80-84, 85-89 ve 90-100 şeklinde aralıklarla 9 kategori belirlenmiştir.

Yapay sinir ağları modellerinden çok katmanlı algılayıcı ağ ile yapılan bu analizde, analize hazır hale getirilen veri setinin %70'i eğitim, %15'i geçerlilik ve %15'i de test için kullanılmıştır. Ağın eğitimi sırasında sinirler arasındaki bağlantı ağırlıkları başlangıçta rastgele oluşturulmuştur. Bu noktada yapay sinir ağları, en iyi sonucu alana kadar ağırlıkları değiştirerek ağın eğitimi sağlamıştır. Eğitim sonunda en uygun ağ yapısı belirlenerek MSE (mean square error) değerleri (hata kareler ortalaması) incelenmiştir.

Bulgular:

Araştırmanın veri setinde 142 girdi ve 9 çıktı verisi bulunmaktadır. Bu girdi ve çıktı katmanları arasında bulunan gizli katman nöron sayısı en iyi sonucu elde edebilmek amacıyla değiştirilerek Tablo 1’deki dokuz ağ yapısı oluşturulmuştur. Rastgele değiştirilen her gizli katman nöron sayısı ile oluşturulan ağ modelinde eğitim, geçerlilik ve test veri setleri için hata kareler ortalaması incelenmiştir. Bu üç veri seti için ağ tarafından hesaplanan MSE değerleri ile ağ yapılarına ilişkin bulgular Tablo 1’de yer almaktadır.

Tablo 1

Veri setinin %70’inin eğitim, %15’inin geçerlilik ve %15’inin test için kullanıldığı MSE (Hata Kareler Ortalaması) değerleri

Gizli Katman Nöron Sayısı	MSE (Hata Kareler Ortalaması)		
	Eğitim	Geçerlilik	Test
10	0.090	0.040	0.040
13	0.090	0.050	0.300
15	0.050	0.040	0.200
18	0.090	0.010	0.040
20	0.080	0.008	0.008
23	0.050	0.008	0.008
25	0.030	0.004	0.005
28	0.030	0.004	0.100
30	0.060	0.100	0.400

Tablo 1 incelendiğinde, oluşturulan ağ modelleri arasında en az hatanın 25 gizli katman nöron sayısının bulunduğu ağ yapısı için hesaplandığı görülmüştür. Burada amaç, beklenen veri ile çıktı veri arasında en az hatanın yapıldığı ağın bulunmasını sağlamaktır. Bu yapının hata kareler ortalamalarına bakıldığında ise eğitim veri seti için 0.03, geçerlilik veri seti için 0.004 ve test veri seti için de 0.005 olduğu görülmektedir.

Tartışma ve Sonuç:

a. Tartışma:

Kişilerin başarı durumlarını etkileyen birçok faktör bulunmaktadır. Yapılan bu çalışmada bu faktörlerden cinsiyet, yaş, baskın zekâ alanı ve çalışma alışkanlıkları ele alınmıştır. Başarıyı etkileyen değişkenlere göre başarı sınıflandırması yapılması bireylere sunulacak öğretim kalitesini arttırabilecektir.

Konuyla ilgili literatür incelendiğinde eğitim alanında öğrenci başarısını yapay sinir ağları yardımıyla sınıflandıran pek fazla çalışma bulunmamaktadır. Öğrencileri çeşitli değişkenler doğrultusunda başarılı-başarısız olarak sınıflandırmak için karar ağaçları ve YSA'nın karşılaştırıldığı çalışmada, YSA daha yüksek bir başarı oranı ile sınıflandırma işlemini gerçekleştirmiştir (Tosun 2007). Yapılan bir diğer araştırmada ise, öğrenci başarılarının sınıflandırılmasına olanak sağlayacak modeller üzerine çalışılmıştır. Lojistik Regresyon Analizi ile YSA'nın karşılaştırıldığı bu çalışmada da YSA diğer modele göre daha yüksek doğrulukta sınıflandırma sağlamıştır (Çırak ve Çokluk 2013).

Araştırma sonuçlarımıza bakıldığında söz konusu değişkenler için yapay sinir ağlarının çok katmanlı algılayıcı ağ modelinin kullanılabilir olduğu görülmüştür. Hata kareler ortalamalarında (MSE) daha küçük değerler elde edilebilmesi, ağın istenilen sınıflandırmayı daha başarılı yaptığı anlamı taşımaktadır. Örneklem sayısı artırılarak, ağın verileri sınıflandırma performansı yükseltilebilir.

b. Sonuç:

Araştırma sonuçlarına göre yapay sinir ağı modellerinden çok katmanlı algılayıcı ağ modeli yaş, cinsiyet, çalışma alışkanlıkları ve baskın zekâ alanları değişkenleri ile genel not ortalamalarına göre sınıflandırılmasında kullanılabilir. Çalışmada oluşturulan 142-25-9 mimarisine sahip sinir ağında veri setleri için hesaplanan hata kareler ortalaması (MSE) değerleri, ağdan üretmesi beklenen veriler ile çıktı verilerini ne kadar hata ile sınıflandırdığını göstermektedir. Oluşturulan ağı hesaplamış olduğu MSE değerlerine bakıldığında bu değerlerin eğitim veri seti için 0.03, geçerlilik veri seti için 0.004 ve test veri seti için de 0.005 olduğu görülmektedir. Ağ tarafından hesaplanan MSE değerleri örneklem sayısına, giriş ve çıkış veri sayısına, kullanılan algoritmalara ve ağ mimarisine göre değişebilmektedir. Bu nedenle konuyla ilgili yapılan araştırmalarda bu niceliklere dikkat edilmesi gerekmektedir.

c. Öneriler:

Yapılan bu çalışma, YSA'nın eğitim alanında kullanımında literatüre katkıda bulunmaktadır. Ancak örneklem sayısının az olması, beklenen ölçüde iyi sonuçlar elde edilmesine engel olmuştur. Bu nedenle ilerleyen araştırmalarda benzer de-

ğişkenler için daha fazla örnekleme ulaşılması, daha güvenilir sonuçlar elde edilmesini sağlayacaktır. Ayrıca bunların yanı sıra birçok alanda başarılı performans gösteren YSA modelinin fen eğitimine uygulanabilmesi için daha farklı değişkenlerle denemeler yapılarak YSA'nın eğitim alanındaki uygulamalarının arttırılması öneri olarak sunulmaktadır.

Kaynakça:

Kitap, Dergi ve Makaleler:

ANDERSON, Dave & MCNEILL, George, (1992), *Artificial Neural Networks Technology*, New York: Kaman Sciences Corporation.

BAHADIR, Elif & ÖZDEMİR, Ahmet Şükrü, (2016), *Akademik Başarı Tahmininde Yapay Sinir Ağları*, Konya: Burç Yayınevi.

BAİLEY, Regina, (13.10.2017), “Central Nervous System Function” <https://www.thoughtco.com/central-nervous-system-373578> (26.12.2017)

Bilim ve Sanat Terimleri Ana Sözlüğü, http://tdk.gov.tr/index.php?option=com_bilimsanat&view=bilimsanat&kategori=terim&kelimeget=ba%C5%9Far%C4%B1&hngget=md (Erişim: 15.06.2017)

ÇIRAK, Gülçin & ÇOKLUK, Ömay, (2013), “Yükseköğretimde Öğrenci Başarılarının Sınıflandırılmasında Yapay Sinir Ağları ve Lojistik Regresyon Yöntemlerinin Kullanılması”, *Mediterranean Journal of Humanities*, III,2: 71-79. doi:10.13114/MJH/201322471

ELMAS, Çetin, (2016), *Yapay Zeka Uygulamaları*, Ankara: Seçkin Yayıncılık.

ERGÜN, Uçman, SERHATLIOĞLU, Selami, HARDALAÇ, Fırat & GÜLER, İnan, (2004), “Classification of Carotid Artery Stenosis of Patients with Diabetes by Neural Network and Logistic Regression”, *Computers in Biology and Medicine*, XXXIV: 389-405. doi:10.1016/S0010-4825(03)00085-4

FIRAT , Mahmut & GÜNGÖR, Mahmud, (2004), “Aski Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi”, *İMO Teknik Dergi*, 3267-3282.

GÜRSAKAL, Sevda, (2012), “PISA 2009 Öğrenci Başarı Düzeylerini Etkileyen Faktörlerin Değerlendirilmesi”, *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, XVII,1: 441-452.

HOWELL, Robert M. & FOWLER, David, (1990), “A Neural Network as an Instrument of Prediction”, *Proceedings of the Annual Symposium on Computer Application in Medical Care*, 299-302.

İBRAHİM, Zaidah, & RUSLİ, Daliela, (2007), “Predicting Students’ Academic Performance: Comparing Artificial Neural Network, Decision Tree and Linear Regression” *21st Annual SAS Malaysia Forum*, 1-6, Kuala Lumpur.

KAMRUZZAMAN, Joarder, SARKER, Ruhul A., & BEGG, Rezaul K., (2006), *Artificial Neural Networks in Finance and Manufacturing*, Idea Group Publishing.

MOUSTRİS, K. P., NASTOS, P. T., LARİSSİ, I. K. & PALİATSOS, A. G., (2012), “Application of Multiple Linear Regression Models and Artificial Neural Networks

on the Surface Ozone Forecast in the Greater Athens Area, Greece”, **Hindawi Publishing Corporation Advances in Meteorology**, 2012:1-8. doi:10.1155/2012/894714

OLADOKUN, V. O., ADEBANJO, 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**, IX,1: 72-79.

ORAL, Behçet, (2001), “Branşlarına Göre Üniversite Öğrencilerinin Zeka Alanlarının İncelenmesi”, **Eğitim ve Bilim**, XXVI, 122: 19-31.

ÖZER, Yeşim & ANIL, Duygu, (2011), “Öğrencilerin Fen ve Matematik Başarılarını Etkileyen Faktörlerin Yapısal Eşitlik Modeli ile İncelenmesi” **Hacettepe Üniversitesi Eğitim Fakültesi Dergisi**, 41:313-324.

ÖZTEMEL, Ercan, (2016), **Yapay Sinir Ağları**, İstanbul: Papatya Yayıncılık.

RUSSELL, Stuart & NORVIG, Peter, (2010), **Artificial Intelligence A Modern Approach**, New Jersey: Pearson Education.

SNYDER, R. F, (2000), “The Relationship between Learning Styles/Multiple Intelligences and Academic Achievement of High School Students”, **The High School Journal**, LXXXIII,2: 11-20.

ŞİRİN, Selçuk R., (2005), “Socioeconomic Status and Academic Achievement: A Meta-Analytic Review of Research”, **Review of Educational Research**, LXXV,3: 417-453.

TU, Jack V., (1996), “Advantages and Disadvantages of Using Artificial Neural Networks versus Logistic Regression for Predicting Medical Outcomes”, **J Clin Epidemiol**, XLIX,11: 1225-1231. doi:10.1016/S0895-4356(96)00002-9

WONGKHAMDI, Thipsuda & SERESANGTAKUL, Pusadee, (2010), “A Comparison of Classical Discriminant Analysis and Artificial Neural Networks in Predicting Student Graduation Outcomes” **Proceedings of the Second Conference on Knowledge and Smart Technologies**, 29-34.

Tezler:

ATILGAN, Mehmet (1998), **Üniversite Öğrencilerinin Ders Çalışma Alışkanlıkları ile Akademik Başarılarının Karşılaştırılması**. (Yayımlanmamış Yüksek Lisans Tezi) Gaziantep Üniversitesi Sosyal Bilimler Enstitüsü, Gaziantep.

BAHADIR, Elif (2013), **Yapay Sinir Ağları ve Lojistik Regresyon Analizi Yaklaşımları ile Öğretmen Adaylarının Akademik Başarılarının Tahmini**. (Yayımlanmamış Doktora Tezi) Marmara Üniversitesi Eğitim Bilimleri Enstitüsü, İstanbul.

KAYA, Mesude (2001), **Lise 1. Sınıf Öğrencilerine Verimli Ders Çalışma Alışkanlıkları Kazandırmada Grup Rehberliğinin Etkisi**. (Yayımlanmamış Yüksek Lisans Tezi) İnönü Üniversitesi Sosyal Bilimler Enstitüsü, Malatya.

TOSUN, Süleyman (2007), *Sınıflandırmada Yapay Sinir Ağları ve Karar Ağaçları Karşılaştırılması: Öğrenci Başarıları Üzerine Bir Uygulama*. (Yayımlanmamış Yüksek Lisans Tezi) İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.

YURTOĞLU, Hasan (2005), *Yapay Sinir Ağı Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler için Türkiye Örneği*. (Uzmanlık Tezi) Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü .

Extended Abstract:

With the period of Industry 4.0, various concepts have entered into our lives especially in recent years. One of these concepts was Artificial Neural Networks (ANNs). Artificial neural networks, one of the types of artificial intelligence, have the ability to mimic the various features of biological brain. The human being as a biological system, transmits the stimuli received from the environment to the brain through nerve cells. The brain produces a response to these stimuli reaching it. This response is again delivered to the target organ through nerve cells. This is the process of processing data in a biological brain. Data transmission in artificial neural networks is similar. In the artificial neural network, the stimuli coming from the external environment are defined as input data. Artificial neural networks generate a response by processing input data. This response generates the output data of the artificial neural network. The operating system of the artificial neural network can be briefly summarized in this way.

The most striking features that distinguishes artificial neural networks from digital computer systems is that it can realize learning through examples. The ability to learn by living belonging to biological systems can be used in computer environment with artificial neural network technology. By learning the relationship between the inputs and outputs of the data set presented to the network, the artificial neural network can respond to new examples that it has not seen before. With the help of artificial neural networks, data estimation and classification can be performed. The fact that it does not have a linear structure, the ability to learn, to work with incomplete information, to have error tolerance, to make generalizations, to detect possible relationships between variables are the advantages of artificial neural networks in data analysis. Artificial neural networks that model human brain structure have various uses. When the researches are examined, it is seen that there are successful applications in the field of environmental problems, medicine, engineering, economy, tourism and industry. However, the use of artificial neural networks in education has been increasing in recent years.

In artificial neural network studies in the field of education, different personal information is presented as input data to the system according to the purpose. After processing the input data with the help of algorithms, the desired data can be estimated.

The main purpose of this study is to determine the usefulness of artificial neural networks in classifying them according to their grade point averages by using variables such as age, gender, dominant intelligence area and study habits which are thought to affect students' achievement. For this purpose, the data of 30 teacher candidates studying in the science education department were taken into consideration. Personal information form including age, gender and grade point average was used as a data collection tool. In addition, a 60-item inventory of study habits was used to determine students' study habits and a 80-item multiple intelligence inventory was used to determine dominant intelligence areas.

The collected data was computerized and were analyzed with the multilayer perceptron model from the artificial neural network models in Matlab R2012a program. In the analysis, the input data and the target data corresponding to those inputs were shown to the network. Therefore, the network was trained. Age, gender, dominant intelligence area and study habits were used as input data in total 142 items. 9 categories were determined from the grade point averages and these categories formed the output data. 70% of the data set was used for network training, 15% was used for validity, and 15% was used for testing. At the end of the training of the network, the classification performance was examined with the mean squared error values.

In order to find the best performance in the data set with 142 input and 9 output data, 9 ANN architecture were created. In models where the number of hidden layer neurons is changed to 10, 13, 15, 18, 20, 23, 25, 28 and 30, respectively, the best result is the ANN architecture of 25 hidden layer neurons. The mean squared error values calculated for this architecture was found to be 0.03 for the education data set, 0.004 for the validation data set, and 0.005 in the test data set.

The obtained mean squared error values indicate that the proposed network performs a high accuracy classification. In order to improve the classification performance, the number of samples can be increased. The mean squared error values may vary according to the number inputs and outputs, the algorithm used and the network architecture, except the number of samples.