Öğrenci Başarılarının Yapay Sinir Ağları ile Kestirilmesi*

İzzettin AYDOĞAN**, Gürol ZIRHLIOĞLU***

Öz: Bu çalışmayla, öğrencilerin başarı ölçülerini kestirebilen bir modelin geliştirilmesi amaçlanmaktadır. Araştırma verileri Yüzüncü Yıl Üniversitesi 2015 – 2016 Öğretim Yılı Güz Dönemi ve bu dönemde öğrenim gören 2. ve 3. sınıf öğrencilerini kapsamaktadır. Araştırma, amaçlı örnekleme esasıyla, 657’si 3. sınıf ve 392’si 2. sınıf olmak üzere 1049 öğrenci üzerinden yürütülmüştür. Veriler, araştırmacı tarafından geliştirilen demografik bilgi formu aracılığıyla elde edilmiştir. Çalışmada, 17’si girdi, 1’i çıktı olmak üzere 18 değişkenin yer aldığı Yapay Sinir Ağları yöntemiyle geliştirilen bir tahmin modeli oluşturulmuştur. Modelin geliştirilmesi 3. sınıf öğrenci verileri kullanılarak gerçekleştirilmişken, geliştirilen bu model ile 2. sınıf öğrenci verileri kullanılarak bu öğrencilerin başarı ölçüleri kestirilmiştir. Elde edilen sonuçlar, Sınıflama (Kontenjans) Tabloları, Ki-kare testi, Basit Doğrusal Regresyon Analizi ve Korelasyon Analizi yöntemleri aracılığıyla doğrulanmış ve karşılaştırılmıştır. Bu sonuçlara göre, kestirilen başarı ölçüleri ile gözlenen başarı ölçülerinin ve bu ölçülerle oluşan başarılı/başarısız şeklindeki başarı sınıflandırılmasının önemli ölçüde benzerlik gösterdiği görülmüştür.

Anahtar Sözcükler: Yapay sinir ağları, öğrenci başarısı, kestirim

* Bu çalışma birinci yazarın “Öğrenci Başarılarının Yapay Sinir ile Kestirilmesi ve Lojistik Regresyon Analizi İle Etki Modellerinin Etkililiğinin Karşılaştırılması ” adlı yüksek lisans tez çalışmasının bir bölümünden üretilmiştir.

** Doktora Öğrencisi, Hacettepe Üniversitesi, Eğitim Bilimleri Bölümü, Eğitimde Ölçme ve Değerlendirme Bilim Dalı, İletişim: ayd.izzet@gmail.com, Orcid ID, 0000-0002-5908-1285

*** Dr. Öğretim Üyesi, Yüzüncü Yıl Üniversitesi, Eğitim Bilimleri Bölümü, Eğitimde Ölçme ve Değerlendirme Bilim Dalı, İletişim: gurolyyu@gmail.com Orcid ID, 0000-0001-8687-1349

Estimation of Student Successes By Artificial Neural Networks

Abstract: The aim of this study is to improve a model that estimates the students' success scores. The survey data covers sophomores (2nd year students) and juniors (3rd year students) of fall semester of Yüzüncü Yıl University in 2015 – 2016. The study, based on purposive sampling, was carried out with 1049 students; 657 students of them were juniors and 392 students were sophomores. The data was obtained through a demographic information form which was improved by the researcher. In this study, an estimation model was constituted using artificial neural Networks that has 18 variable, 17 input and 1 output. The development of model was carried out using the data of juniors. Using this developed model with the data of sophomores, the success scores of these students was predicted. The results obtained was verified and compared utilizing classification (contingency) tables, chi square test, simple linear regression analysis and correlation analysis. According to these results it was observed that predicted success scores showed similarity with the observed success scores greatly and with the success classification formed by these scores as successful/ unsuccessful.

Key words: Artificial neural networks, student success, estimation

Giriş

Bilimin merak odaklı arayışları günden güne farklı problem durumlarıyla karşılaşarak, insanoğlunun her anlamda gelişimini ve bilimsel çalışmaların daha ilerilere taşınmasını sağlamaktadır. Geçmişten günümüze bilim dünyasındaki güncelliğini koruyan problemlerden biri, hiç kuşkusuz, insan beyninin çalışma prensibi olmuştur. Beynin nasıl işlev gösterdiği, nasıl tepki ürettiği, böylesi mükemmel bir yapıya nasıl sahip olduğu gibi sorulara cevaplar aranmıştır

(Doğan, 2002, 33). Bu arayışlar, bilgisayar biliminin de içinde olduğu çeşitli bilim dallarının gelişimine ön ayak olmuştur. Bilgisayar bilimi, insan beyninin sergilemiş olduğu benzer özellikleri barındırarak, günümüzde insanların vazgeçilmez bir parçası haline gelmiştir (Şen, 2004, 7). Gelişen bilgisayar bilimi ve matematik biliminin birleştirilerek insan beyninin nöron yapısının taklit edilmesi fikrinin ortaya atılması, bilim insanlarının dikkatlerini bu odak etrafında toplamıştır. Bu alanda çalışmalar yapılmış, bu fikir geliştirilmiş ve beynin göstermiş olduğu işlevleri taklit eden, matematiksel bağıntılarla desteklenmiş bilgisayar programları geliştirilmeye başlanmıştır. Günden güne gelişen bu bilim dalı yapay zekâ adını almıştır (Deperlioğlu & Köse, 2011; Elmas, 2003, 22; Öztemel, 2003, 13). Yapay zekâ, insan beyninin çalışma sistemini, insan zekâsına has; bilgi edinme, algılama, karar verme vs. gibi olguların bilgisayar ortamına aktarılıp bu fonksiyonların geliştirilen yazılımlarla yapılması olarak tanımlanabilir (Baş, 2006; Elmas, 2003, 21; Haton ve Haton, 1989/1991, 7). Yapay zekânın ilerlemesiyle hızlı çalışabilir, bilgiyi depolayabilen, karmaşık ve çözümsüz problemlerin üstesinden gelebilen; öğrenme, bilgiyi işleme, karar verme, problem çözme, sorgulama, yorumlama gibi özellikleri içeren programlar geliştirilmiş ve matematiksel anlamda formüle edilemeyen, çözümü mümkün olmayan problemlerin çözülmesi sağlanmıştır (Öztemel, 2003, 14). Son yarım asır içerisinde önemli ilerlemeler kat eden yapay zekâ, yirminci yüzyılın sonlarına doğru yapılan çok sayıda araştırma ve bu alanda uzmanlaşmış şirketler sayesinde geçerlilik kazanmıştır (Öztemel, 2003, 14; Haton ve Haton, 1989/1991, 9-10). Günümüzde altmıştan fazla yapay zekâ teknolojilerinden bahsedilmekte olup bunlar arasında yaygın olarak kullanılmakta olanlar; Uzman Sistemler, Bulanık Mantık, Genetik Algoritmalar ve Yapay Sinir Ağları (YSA)'dır (Elmas, 2003, 21; Öztemel, 2003, 15).

YSA, biyolojik sinir sistemlerine benzer şekilde gerçek yaşamla etkileşim halindeki hiyerarşik olguların paralel ve iç içe bağlantı kurduğu ağ yapılarıdır (Kohonen, 1987; Akt:

Taşgetiren, 2005). YSA, doğrusal olmayan, çok boyutlu, gürültülü, karmaşık, eksik, kusurlu, kesin olmayan, hata olasılığı yüksek, problemin çözümüne ait matematiksel model ve algoritmanın olmadığı durumları içeren çeşitli uygulamalarda başarılı sonuçlar vermektedir (Öztemel, 2003, 36). YSA'nın yapısal anlamda ve öğrenme anlamında çeşitlilik göstermesi araştırmacılara farklı ve çok sayıda kullanım olanağı sağlamaktadır (Efe ve Kaynak, 2000, 3). Bu nitelikler, YSA'nın farklı amaçlarla uygulanabilir olması özelliğini ortaya koymakta olup bu amaçlardan bazıları sınıflama, kümeleme, vektör sayısallaştırması, desen uygunluğu, fonksiyon yaklaşımı, kestirim (tahmin) yapma, kontrol sorunları, optimizasyon (en iyileme), ve arama çalışmalarıdır (Şen, 2004, 17-18).

Diğer taraftan, üstlendiği rol ve sahip olduğu işleve dayanarak, eğitim olgusunun; toplumların gelişmişlik, üretkenlik, çağdaşlık gibi hususlar itibariyle ilerleme göstermesinde önemli derecede söz sahibi olduğu söylenebilmektedir. Doğumdan ölüme, zihinsel ve fiziksel davranış değişimleriyle tanımlanan öğrenme süreçlerinin koordinasyonu olarak ifade edilen eğitimin çeşitli kuram ve teorilerle beslenmesiyle, insan davranışlarının en iyi nasıl geliştirilip kontrol edileceği üzerine çözümlemeler yapılmıştır. Zamanla eğitim, ailede başlayıp küçük yaşlardan itibaren çevresel ve örgütsel otoriteler kontrolünde ilerleyen bir organizasyon haline gelmiştir. Yani, bireylerin eğitimi; doğuştan itibaren çeşitli çevresel ve örgütsel yapılanmalarla desteklenerek, farklı alanlarda öğrenmelerin sağlanması durumuna dönüşmüştür (Seven ve Engin, 2008; Gökalp, 2006). İnsanlarda meydana gelen değişimlerin ürünü olarak, bireylerin sahip oldukları hareketleri yani davranışları göstermek mümkündür (Seven ve Engin, 2008). Öğrenmenin ne derece gerçekleştiği, bireyin öğrenmelerinin ne düzeyde değiştiği, davranışlar üzerinden gözlemlenebilmektedir. Böylece, öğrenme sürecindeki davranış değişikliklerinin ölçülüp, öğrenmenin değerlendirilmesi fırsatı ortaya çıkmaktadır (Karip, 2012, 12). Buna paralel olarak, öğretilen ya da öğrenilenlerin ne derece etkili olduğu, hangi öğrenmelerin eksik

kaldığı ya da ne düzeyde kazanıldığı gibi dönütlere ihtiyaç duyulmuştur (Demirtaşlı, 2014, 400). Bu dönütler farklı amaç ve pozisyonlarda kullanılmak üzere çeşitlilik göstermiş; ölçme ve değerlendirme açısından seçme, tanıma, yerleştirme, aile ve öğrenciye geri bildirim sağlama gibi durumlarda belirleyici nitelikte olmuştur (Demirtaşlı, 2014, 52-53-54-55; Turgut ve Baykul, 2013, 72-73). Ayrıca bu dönütlerden yararlanılarak gerek bireysel anlamda gerekse örgütsel yapılanmalar tarafından yeterlilik, karşılaştırma gibi durumların gözlenebilir olmasının sağlanması amacıyla, başarı kavramının ortaya çıkması söz konusu olmuştur. Başarı, amaçlanan sonuca ulaşma çabası olarak tanımlanır (Wolman, 1973; Akt: Memduhoğlu ve Tanhan, 2013). Akademik başarı ise, genellikle, okutulan derslerin kazandırdığı beceri ya da bilgilerin öğretmen takdiri notlar ya da test puanlarıyla ya da her ikisiyle ifadesi olarak tanımlanır (Carter ve Good, 1973; Akt: Memduhoğlu ve Tanhan, 2013). Ahmann ve Stanley Marvin'e (1971) göre akademik başarı, öğrencilerin psikomotor ve duyuşsal gelişimi dışında kalan bilişsel davranış gelişimleri olarak ifade edilir (Akt: Memduhoğlu ve Tanhan, 2013). Böylelikle, öğrenmelerin dönütsel eldelerinin not, puan gibi çeşitli ölçüm değerleriyle ifade edilip, akademik başarı denilen göstergelere göre yorumlanması sağlanmıştır (Turgut ve Baykul, 2013, 354; Karip, 2012, 6). Akademik başarı faktörünün, eğitim süreçlerinin dönütsel anlamda göstergesi olarak ifade edilmesi, eğitimin önemli ve çeşitli açılardan yorumlanmasını sağlamıştır. Akademik başarının eğitim ve eğitim süreçleri üzerindeki etkileri bu bağlamda önemli bir paya sahip olmaktadır (Özgüven, 1998; Akt: Çitil, İspir, Söğüt ve Büyükkasap, 2006).

Bu çalışmayla, YSA'nın kestirim (tahmin) alanındaki yeteneğini akademik başarı ile buluşturmak üzere; YSA kullanılarak öğrenci başarılarını erken kestirebilen bir model geliştirilmesi düşünülmektedir. Böylelikle öğrenci başarılarını temsil eden başarı ölçüleri aracılığı ile öğrenci başarılarının erken kestirilebilir olmasının mümkün olup olmadığı

araştırılmak istenmektedir. Bu problem durumu doğrultusunda aşağıdaki alt problem durumlarına cevap aranacaktır:

1. Üniversite öğrencilerinin başarı ölçülerini erken kestirebilmek üzere geliştirilmiş model hangi özelliklere sahiptir?

2. Kestirilen başarı ölçüleri öğrencilerin gözlenen başarı ölçüleri ile ne düzeyde benzerlik göstermektedir?

Yapay Sinir Ağları (YSA)

Yapay zekâ biliminin alt dallarından biri olan yapay sinir ağları (YSA); Elmas'a (2003, 23) göre, birbiriyle bağlanan ağırlıklı bağlantıların oluşturduğu, insan beyninin sinir ağlarına benzeyen ve kendi içinde belli bir belleğe sahip olan paralel bilgi işleme sistemleridir. Diğer bir tanımıyla, YSA, sinir sistemindeki biyolojik ağ yapısını taklit edinmek üzere hazırlanmış bilgisayar programlarıdır. Öztemel'e (2003, 29) göre, insan beynine ait özellikler olan öğrenme, yeni bilgiler üretme, bilgileri keşfetme gibi olguları kendi başına gerçekleştirmek amacıyla geliştirilmiş bilgisayar programlarıdır. Efe ve Kaynak'a (2000, 1) göre, beyni oluşturan biyolojik hücrelerin (nöronlar) çalışma ilkelerini taklit eden sayısal bilgisayarlar aracılığıyla bilgilerin işlenip, biyolojik nöron dinamiğiyle bir çıktıya dönüştürüldüğü bilim dalıdır.

Biyolojik sinir ağlarında olduğu gibi YSA'da da temel bilginin işlendiği en küçük temel unsur sinir hücresidir. Yapay sinir hücreleri bir ya da birden fazla girdi alarak çıkış üretirler ve bu çıkışlar başka nöronların girişi olabilir (Saraç, 2004). YSA, yapay sinir hücrelerinin (proses elamanları) çeşitli bağlantılar vasıtasıyla bir araya gelerek bir ağ bileşeni oluşturmasıyla elde edilir. Bu yapı nöronların oluşturdukları sinir ağlarına benzer şekildedir. Her bir hücre sütunu

katman olarak adlandırılmaktadır. Hücreler arasındaki bağlantılar ağırlık adı verilen değerlerle donatılmış olup, bu ağırlıklar hücreler arası etkileşimi ve etkinliği temsil eder. Ağ yapısı, giriş verileri ve çıkış verileri arasında bir takım algoritmalar oluşturularak girdi verilerinin bir çıkarım verisi eldesi kuramıyla modellenir. Modellemeler ağı öğrenme esasına dayanır. İnsanların yaşamış oldukları örnek olaylardan yaralanarak geliştirilen öğrenme süreci tamamlandıktan sonra, ilişkilendirme, genelleme, sınıflama, özellik belirleme, optimizasyon gibi fonksiyonları yerine getirebilen; öğrenmelerini kendi deneyimlerine dönüştürebilen; sonrasında, gelen benzer uyarılara karşı tepkiler üretebilen, karar mekanizmaları oluşturabilen YSA elde edilmiş olur (Saraç, 2004; Öztemel, 2003, 29-30).

Bir yapay sinir hücresi; girdi, ağırlık, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktı olmak üzere beş bileşenden oluşmaktadır (Saraç, 2004).

Şekil 1. Yapay Sinir Hücresi (Örkcü, 2009)

Şekil 1 ile bir YSA hücresi ifade edilmektedir. Girdiler: Evreden, dış dünyadan gelen bilgilerin sinir hücresine girişini sağlar (Öztemel, 2003, 49; Elmas, 2003, 33). Ağırlıklar: Hücreye gelen girdi bilgilerinin hücre için önemini ve etkisini gösteren matematiksel değerlerdir. Her bir girdi kendine ait bir ağırlığa sahip olur. Ağırlık değerlerinin pozitif ya da negatif olması etkinin yönünü ve büyük ya da küçük oluşu etkinin gücünü göstermektedir. Sıfır oluşu ise, etkinin olmadığı anlamına gelmektedir (Öztemel, 2003, 49; Elmas, 2003, 33).

Toplama Fonksiyonu: Hücreye gelen net girdiyi hesaplayan fonksiyondur. Toplama fonksiyonu olarak farklı denklemlerin varlığından söz edilebilir ama en uygun olanı ağırlıklı toplamı bulmaktır. Her bir ağırlığın girişlerle çarpımının toplamı eşik değeri ile toplanarak elde edilen değer aktivasyon fonksiyonuna gönderilir (Öztemel, 2003, 49; Elmas, 2003, 33). w ağırlıklar matrisi, x girdi matrisi ve n girdi sayısı olmak üzere NET girdi değeri; $NET = \sum_{i=1}^n w_{ij}x_i + \theta_j$ formülü ile hesaplanır (Örkcü, 2009). Aktivasyon Fonksiyonu: Toplama fonksiyonundan gelen net girdiyi işleyerek hücre girdisine karşılık gelecek olan çıktı değerini üretir. Transfer fonksiyonu olarak da bilinen aktivasyon fonksiyonu, genellikle doğrusal olmayan ve çeşitlilik gösteren fonksiyonlardır (Saraç, 2004; Öztemel, 2003, 50). f aktivasyon fonksiyonu olmak üzere, $f(NET) = f(\sum_{i=1}^n w_{ij}x_i + \theta_j)$ 'dir (Örkcü, 2009). Çıktılar: Hücreye gelen girdi ya da girdilerin işlenerek bir çıkış değerine ulaştığı yerdir. Her bir sinir hücresinin birden fazla girdisi olsa da, sadece bir çıktısı olabilir. Elde edilen çıktı dış dünyaya ya da diğer hücrelere girdi olarak gönderilir (Öztemel, 2003, 51; Elmas, 2003, 35).

Yapay sinir hücreleri bağlantılar aracılığıyla birbirlerine bağlanıp, katmanları oluştururlar. Bir YSA; girdi, ara (gizli) ve çıktı katmanı olmak üzere üç katman yapısından oluşur (Baş, 2006; Şen, 2004, 66; Saraç, 2004; Öztemel, 2003, 52-53; Elmas, 2003, 43):

Şekil 2. Bir Yapay Sinir Ağ Yapısı Örneği (Kaynak; Teknosektör).

Şekil 2 ile bir YSA yapısı ifade edilmektedir. Girdi Katmanı: Dışarıdan gelen bilgileri ara (gizli) katmana iletmekle görevli hücrelerden oluşurlar. Ara (gizli) Katman: Girdi katmanından gelen bilgileri işleyerek çıktı katmanına iletir. Bu katmanda doğrusal olmayan davranışları sağlayan işlemler mevcuttur ve bilgiler bu katmandaki hücrelerde işlenir. Bir YSA’da birden fazla ara katman olabilir. Çıktı Katmanı: Ara katmandan gelen bilgileri işleyerek girdi setine karşılık gelen çıktı setini üretirler.

Giriş bilgilerinin yapay sinir hücresine gelmesiyle birlikte her bir girdi değerine ait rastgele ağırlık değerleri oluşur. Ağa gelen sonraki örneklere paralel olarak ağırlık değerleri değişir. Buradaki amaç, doğru çıktıya ulaşabilmek için en uygun ağırlık değerlerini elde etmektir. Dolayısıyla ağa defalarca gösterilen örnekler sayesinde ağın en doğru ağırlık değerlerini elde etmesi sağlanır. Ağ bağlantılarının hücre içi ağırlık değerlerinin bu şekilde belirlenmesi işlemine ağın eğitilmesi denir. Ağın eğitilmesi, hata miktarını en aza indirmeyi sağlayan ağırlık değerlerini elde etmek anlamına gelmektedir. Eğitilen ağ, mevcut problem durumu üzerine genelleme yapabilme özelliği kazanmış olur, buna da ağın öğrenmesi denir.

Ağın genelleme özelliğine ve çıktıya ulaşabilir en doğru ağırlık değerlerine ulaşabilmesi, ağırlık değerlerinin değişmesi, öğrenme stratejilerine göre şekillenen öğrenme kuralları adı verilen algoritmalar aracılığıyla sağlanmaktadır (Şen, 2004, 93-94; Öztemel, 2003, 55). Ağın eğitimi tamamlandıktan sonra, ağın öğrenmesi sürecinde ağın görmediği örnekler kullanılarak öğrenmenin gerçekleşip gerçekleşmediği tecrübe edilir. Bu işleme ağın test edilmesi denir. Test sürecinde ağıdaki ağırlık değerleri değişmez, belirlenen ağırlık değerleri kullanılarak çıktı üretilmesi sağlanır ve elde edilen çıktıların doğruluk düzeyleri, ağın öğrenmesi ve performansı hakkında bilgi verir. Ağın eğitimi sürecinde kullanılan örnek setine eğitim seti, testi sürecinde kullanılan örnek setine test seti denir (Öztemel, 2003, 56).

YSA, kullanılan işlemci elemanlarının bağlantı şekilleriyle oluşan mimarı ve bağlantılarda kullanılan öğrenme algoritmalarına göre sınıflandırılmaktadır (Baş, 2006; Gülseçen, 1993; Akt: Baş, 2006). Bir yapay sinir ağının işlemci elemanlarının bağlantı şekilleri ağ topolojisi olarak ifade edilmektedir. Topolojiye göre YSA, ileri beslemeli ve geri beslemeli ağlar olmak üzere iki türdür (Gülseçen, 1993; Akt: Baş, 2006). YSA'nın eğitilmesi yani öğrenmesi, hücre bağlantıları üzerindeki ağırlıkların değiştirilmesiyle gerçekleşmektedir (Elmas, 2003, 95). Bu değişim, matematiksel anlamda birtakım yöntem, kural ve algoritmaların yenilenmesidir. Her ağ modeli kendine göre bir öğrenme algoritması kullanmaktadır. Genel olarak, öğrenme metoduna göre ağlar, danışmanlı (öğretmenli) ve danışmansız (öğretmensiz) öğrenme esasına göre iki şekilde ele alınmaktadır (Baş, 2006).

Amaç ve Önem

Araştırmanın amacı, üniversite öğrencilerinin verilere ulaşılan dönemin (2015 – 2016 Öğretim yılı Güz Dönemi) sonunda elde edecekleri başarı ölçülerini (Ağırlıklı Genel Not Ortalaması) (AGNO) belirtilen dönemin içerisinde kestirebilmede kullanılabilecek bir model

geliştirmektir. Böylelikle, öğrencilerin dönem sonunda elde edeceği başarı ölçülerini dönem içerisinde kestirebilecek; gerek görülmesi durumunda uygun müdahalelerle başarı düzeylerinin artmasına dönük tedbirler belirlenebilecektir. Bunun yanında, öğrencilerin başarı ölçülerinin yapılmış araştırmalar sonucunda ortaya çıkan başarıyı etkileyen faktörler üzerinden modellenerek kestirilmesi ile YSA'nın kestirim yöntemiyle yapılan çalışmalarda gösterdiği performansın test edilmesi istenmektedir. Bu durumun, günümüze kadar yapılmış olan çalışmalarda vurgulanan, öğrenci başarılarını etkileyen değişkenlerin öneminin değerlendirilmesi fırsatını ortaya koyması hususuyla önem taşıyabileceği düşünülmektedir.

Yöntem

Araştırma, nicel araştırma türlerinden tarama modeliyle yürütülmüştür. Tarama modeli, bir gruba ait belirli özelliklerin belirlenmesi amacıyla verilerin toplanması ve kullanılmasına dayanan araştırma çeşididir (Büyüköztürk, Çakmak, Akgün, Karadeniz ve Demirel, 2014, 14). Bu çerçevede, araştırmanın amacına uygun örneklem ve değişkenlere ait veriler, araştırmacı tarafından veri toplama aracı olarak geliştirilen bilgi formu aracılığıyla elde edilmiştir. Araştırmanın evren ve örneklemine, veri toplama aracı ve verilerin toplanma şekline, verilerin nasıl analiz edildiğine aşağıda yer verilmiştir.

Çalışma Grubu

Araştırma evrenini, Yüzüncü Yıl Üniversitesi'nde öğrenim gören 2015-2016 öğretim yılı Güz dönemi lisans öğrencileri oluşturmaktadır. Bu evreni oluşturan sayı yaklaşık olarak 17 bin olup, araştırma için yeterli örneklem sayısı 380 olarak belirlenmiştir (Büyüköztürk vd., 2014, 95).

Çalışmada, amaçsal örnekleme esasıyla, YSA ile oluşturulan tahmin modelinde 2. ve 3. sınıf öğrencilerinin verileri kullanılmıştır. Amaçsal örnekleme, belirli özelliklere sahip özel durumları içeren, çalışmanın amacına bağlı olarak istenilen bilgileri zengin ölçüde taşıyan durumların seçilerek araştırma yapılmasını sağlayan nitelik taşıır (Büyüköztürk vd., 2014, 90).

Araştırmanın YSA ile oluşturulan tahmin modelinin geliştirilmesi, 366 kız ve 291 erkekten oluşan toplam 657 üçüncü sınıf öğrencisi ile gerçekleşmiştir. Geliştirilen YSA modeli ile 205'i erkek ve 187'si kız olmak üzere 392 ikinci sınıf öğrencisinin 3. dönem sonu başarı ölçüleri (AGNO değerleri) kestirilmiştir.

Veri Toplama Aracının Geliştirilmesi

Araştırmacı tarafından, araştırmanın içeriğiyle ilgili literatürden (Sayın ve Gelbal, 2014; Metin, 2013; Aslantaş, Özkan ve Külekçi, 2012; Gürsakal, 2012; Savaş, Taş & Duru, 2010; Anıl, 2009; Seven ve Engin, 2008; Yüksel ve Sezgin, 2008; Çitil vd., 2006; Ekşioğlu, 2005; Şeker, Çınar ve Özkaya, 2004; Peker, 2003; Büyüköztürk ve Deryakulu, 2002; Atan, Göksel ve Karpaz, 2002) yararlanılarak, öğrenci başarılarını etkileyen demografik unsurların neler olduğu araştırılmış ve bu unsurlar 17 maddelik bir yapı ile açıklanmak istenmiştir. Eğitim bilimleri alanında uzman 5 öğretim üyesinin görüşleri, düzeltmeleri ve onayları doğrultusunda, bu maddelerin öğrenci başarılarını etkileyen demografik yapıda işlev göstereceği kanaatine varılmıştır. Böylece, araştırmanın amacı doğrultusunda veri toplama aracı olmak üzere demografik bilgi formu oluşturulmuş ve 2. ve 3. sınıf öğrencilerine uygulanarak, tahmin modelinin verilerini elde etmek üzere yararlanılmıştır.

Bilgi formundaki maddelerinin her biri modelleme için birer değişkeni ifade etmiştir. Bu değişkenlerin neler olduğuna çalışmanın bulgular kısmında modelin oluşturulmasıyla ilgili bölümlerde yer verilmiştir.

Verilerin Çözümlemesi

Veriler, analiz edilmeye hazır düzeye getirildikten sonra analiz ortamına aktarılmış ve bütün analizler istatistik paket programı aracılığıyla gerçekleştirilmiştir. Uygulanan analiz ve istatistik çalışmaları aşağıda belirtilen şekilde gerçekleştirilmiştir;

1. Üçüncü sınıf öğrenci verileri aracılığıyla YSA yöntemi kullanılarak 3. dönem sonu başarı ölçülerini kestiren bir model geliştirilmiştir.

2. Geliştirilen bu modele 2. sınıf öğrencilerinin verileri tanıtılarak 3. dönem sonu başarı ölçüleri kestirilmiştir.

3. Kestirilen başarı ölçüleri ile gözlenen başarı ölçüleri arasındaki ilişki ve uyum, Basit Doğrusal Regresyon Analizi, Korelasyon Analizi teknikleri kullanılarak belirlenmiştir.

4. Kestirilen ve gözlenen başarı ölçüleri üniversitenin geçme notu olan 60 değerine göre başarılı/başarısız olmak üzere kategorileştirilmiş, Sınıflama (Kontenjans) Tabloları ve Ki-kare testi teknikleri aracılığıyla karşılaştırılmıştır.

Bulgular ve Yorum

Geliştirilen tahmin modeliyle ilişkili olarak, birinci ve ikinci alt problemlerle ilgili olarak aranan cevaplara ait bulgular ve yorumlara aşağıda yer verilmiştir.

Birinci Alt Probleme İlişkin Bulgular ve Yorumlar

Araştırmanın birinci alt problemi ‘Üniversite öğrencilerinin başarı ölçülerini erken kestirebilmek üzere geliştirilmiş model hangi özelliklere sahiptir?’ şeklinde ifade edilmiştir. 3. sınıf öğrenci verileri aracılığıyla 2. sınıf öğrencilerinin 3. dönem sonu başarı ölçülerini kestiren bir modelin geliştirilmesi; bu modele istenen özellikteki bir 2. sınıf öğrenci veri seti tanıtıldığında bu veriler üzerinden bu öğrencinin 3. dönem sonu başarı ölçüsünün kestirilmesi, çalışmanın önemli unsuru olmuştur. Bu amaç doğrultusunda oluşturulan tahmin modelinde yer alan değişkenler Tablo 1’de sunulmuştur.

Tablo 1. Tahmin Modelinde Yer Alan Değişkenler

Değişkenler	
Girdi	Çıktı
X_1 : Fakülte	Y: 3. dönem sonu başarı ölçüsü (AGNO)
X_2 : Bölüm	
X_3 : Yaş	
X_4 : Cinsiyet	
X_5 : Mezun olduğu lise türü	
X_6 : Lise diploma notu	
X_7 : Bölüme yerleştiği ösym puanı	
X_8 : Bölüme yerleştiği puan türü	
X_9 : 2. dönem sonu başarı ölçüsü (AGNO)	
X_{10} : Kardeş sayısı	
X_{11} : Annenin eğitim durumu	
X_{12} : Babanın eğitim durumu	
X_{13} : Anne ve babanın birliktelik durumu	
X_{14} : Aile ile birlikte yaşama durumu	
X_{15} : Ailenin ortalama aylık geliri	
X_{16} : Uzun süre ikamet edilen il	
X_{17} : Bölüme severek isteyerek yerleşme durumu	

Model, YSA yöntemi aracılığıyla oluşturulmuştur. Her bir 3. sınıf öğrencisine ait Tablo 1’de belirtilmiş olan 17 girdi, 1 çıktı değişkeni kullanılarak model eğitilmiş ve modelden her bir girdi seti için, başarı ölçüsünün çıktı olarak kestirilmesi sağlanmıştır. Modelde yer alan girdi değişkenlerinden X_3 , X_6 , X_7 , X_9 ve X_{10} değişkenleri sürekli yapıda olup, diğer değişkenler ise

kategorik yapıdaki değişkenlerdir. X_{16} değişkeni verilen yanıtların SEGE-2011 (Kalkınma Bakanlığı, 2013) raporunda belirtilen gelişmişlik düzeyine göre gruplandırılması esasıyla kodlanmıştır. Modelin eğitimi tamamlandıktan sonra yine Tablo 1’de belirtilen 17 girdi değişkeni modele tanıtılarak, her bir 2. sınıf öğrencisi için 3. dönem sonu başarı ölçüsü çıktı olarak üretilmiştir.

Modelin eğitilmesinde yararlanılan 3. sınıf öğrencilerine ait verilerin kullanım amaçları Tablo 2’de verilmiştir.

Tablo 2. Tahmin Modelinin Geliştirilmesinde Kullanılan Veri Seti

Kullanım alanı	n	%
Eğitim (training)	355	54
Test (testing)	191	29,1
Geçerlilik (holdout)	111	16,9
Toplam	657	100

Modelin eğitilmesi aşamasında, ağın öğrenmesi işlemi Tablo 2’de belirtilen 355’i eğitim, 191’i test ve 111’i geçerlilik olmak üzere 3. sınıf öğrencilerine ait toplam 657 öğrenci verisi aracılığıyla gerçekleşmiştir. Bu oran ve sayılar deneme yanılma esasına dayanarak, en iyi sonucu veren modeli elde etmek amacıyla değişkenlik gösterebilir. Bu oranlamayı Turhan, Kurt & Engin (2013) çalışmalarında % 50 eğitim, % 25 test ve % 25 geçerlilik şeklinde kullanmışlarken; Çırak (2012) çalışmasında % 54,2 eğitim, % 15,3 test ve % 30,5 geçerlilik; Oladokun, Adebajo & Charles-Owabo (2008) çalışmalarında % 56 eğitim, % 30 test ve % 14 geçerlilik; Şen (2004, 80) % 40 eğitim, % 30 test ve % 30 geçerlilik şeklinde ifade etmiştir. Bu sayı ya da oranlamanın ağın performansına göre değişebileceği vurgusunu Saraç (2004) da yapmıştır. Çalışmada kullanılan bu oran ve sayıların belirlenmesindeki etken bu bağlamda, en iyi sonucu veren ağın eğitiminin bu değerlerle elde edilmesidir.

Modellemede kullanılan YSA türü, Çok Katmanlı Yapay Sinir Ağı (MLP) olmuştur. Modellenen ağı yapısı Şekil 3’de ifade edilmiş olup, bu ağı özellikleri Tablo 3’de sunulmuştur.

Şekil 3. Modellenen Ağı Yapısı

Tablo 3. Modellenen Ağın Özellikleri

Katman	Katman Sayısı	Hücre Sayısı	Aktivasyon Fonk.
Girdi	1	99	
Ara	1	3	Sigmoid
Çıktı	1	1	Doğrusal
Toplam	3	103	

Modellenen ağ Tablo 3’de belirtildiği üzere, birer girdi, ara ve çıktı katmanından oluşmuş olup; ağın modellenmesinde 17 girdi değişkenine karşılık gelen 99 girdi hücresi, 3 ara katman hücresi ve 1 çıktı hücresi yer almıştır. Ara katmandaki bilgi akışı Sigmoid Aktivasyon Fonksiyonu, çıktı katmanında ise Doğrusal Fonksiyon aracılığıyla sağlanmıştır. Hata fonksiyonu olarak Hata Kareler Toplamı Algoritması kullanılmıştır. Model oluşturma sürecinde; tek ara katmanlı, iki ara katmanlı, ara katmandaki hücre sayısının farklılaşması, ağırlıkların farklı değerle nicelendirilmesi, bilgi akışını sağlayan fonksiyonların farklı şekillerde kombine edilmesi gibi esaslarla 120 farklı ağ oluşturulmuş ve kestirimi en iyi yapan, en az hatayla yapan model araştırılmıştır. Sonuç olarak, en uygun modelin Tablo 3’de belirtilen yapıda olduğu tespit edilmiş ve çalışmanın tahmin modeli bu model olmuştur.

Modeli oluşturan girdi değişkenlerin önem yüzdesi Tablo 4’de sunulmuştur.

Tablo 4. Girdi Değişkenlerin Önem Yüzdesi

Değişken	%
X_9 : 2. dönem sonu başarı ölçüsü (AGNO)	45,1
X_2 : Bölüm	6,7
X_{11} : Annenin eğitim durumu	5,9
X_8 : Bölüme yerleştiği puan türü	5,6
X_1 : Fakülte	4,1
X_{10} : Kardeş sayısı	4,1
X_{13} : Anne babanın birliktelik durumu	4
X_{12} : Babanın eğitim durumu	3,9
X_7 : Bölüme yerleştiği ÖSYM puanı	3,6
X_{17} : Bölüme severek isteyerek yerleşme durumu	3,1
X_3 : Yaş	3,1
X_5 : Mezun olduğu lise türü	3
X_{15} : Ailenin ortalama aylık geliri	2,6
X_6 : Lise diploma notu	2,4
X_{16} : Uzun süre ikamet edilen il	1,6
X_4 : Cinsiyet	0,7
X_{13} : Aile ile birlikte yaşama durumu	0,6
Toplam	100

Oluşturulan modelin girdi değişkenleri olan 17 değişken durumunun ağırlık gelişimindeki önem yüzdeleri Tablo 4’de belirtilmiş olup, görüldüğü üzere modeldeki en önemli değişken % 45,1 önem payı ile ‘2. dönem sonu AGNO’ değeri olmuştur. ‘2. dönem sonu başarı ölçüsü (AGNO)’ değerini % 6,7 ile ‘okuduğu bölüm’, % 5,9 ile ‘anne eğitim durumu’ ve % 5,6 ile ‘bölüme yerleştiği puan türü’ takip etmiştir. ‘Fakülte’ ve ‘ kardeş sayısı’ değişkenleri % 4,1; ‘anne ve babanın birliktelik durumu’ değişkeni % 4; ‘babanın eğitim durumu’ değişkeni %3,9; ‘bölüme yerleştiği ÖSYM puanı’ değişkeni % 3,6; ‘bölüme severek isteyerek yerleşme durumu’ ve ‘yaş’ değişkenleri % 3,1; ‘mezun olduğu lise türü’ değişkeni % 3; ‘ailenin ortalama aylık geliri’ değişkeni % 2,6; ‘lise diploma notu’ değişkeni % 2,4; ‘uzun süre ikamet edilen il’ değişkeni % 1,6; ‘cinsiyet’ değişkeni % 0,7 ve ‘aile ile birlikte yaşama’ değişkeni % 0,6 önem derecesi ile modelde yer almıştır.

İkinci Alt Probleme İlişkin Bulgular ve Yorumlar

Araştırmanın ikinci alt problemi ‘Kestirilen başarı ölçüleri öğrencilerin gözlenen başarı ölçüleri ile ne düzeyde benzerlik göstermektedir?’ şeklinde ifade edilmiştir. Geliştirilmesi, yapısı ve eğitilmesi ile ilgili birinci alt probleme ilişkin bulgular ve yorumlar başlığıyla verilen bilgiler ışığında, çıktı olarak 3. dönem sonu başarı ölçüsü üretmeye hazır hale getirilmiş olan modele 2. sınıf öğrencilerine ait Tablo 1’de belirtilen 17 girdi değişkeni tanıtılarak, modelin her bir 2. sınıf öğrencisi için 3. dönem sonu başarı ölçüsü üretmesi sağlanmıştır.

Aynı öğrencilere ait gözlenen başarı ölçülerine ulaşıldıktan sonra her bir öğrenci için oluşan kestirilen ve gözlenen başarı ölçülerinin karşılaştırılması amacıyla ilk olarak Basit Doğrusal Regresyon Analizi yönteminden yararlanılmıştır. Bu analizin yapılması için gerekli olan veri gruplarının normal dağılım göstermesi koşulunu hem gözlenen hem de kestirilen verilerin sağladığı görülmüştür. Bağımsız değişkenin bağımlı değişkeni anlamlı bir şekilde yordayıp yordamadığı, bağımsız değişkenin bağımlı değişkenin ne kadarını açıkladığı, bağımlı ve bağımsız değişkenlerdeki etkileşim miktarlarının ne olduğu, bağımlı ve bağımsız değişken arasındaki ilişki düzeyi gibi durumların belirlenmesinde istatistiki teknik olarak Basit Doğrusal Regresyon Analizi yöntemini kullanmak mümkündür (Büyüköztürk, 2013, 91). Şen (2004, 167)’e göre, çalışmadaki YSA modeli ve amacına paralel olarak, YSA ile oluşturulan bir modelin ürettiği kestirilen değerler ile gözlenen değerler arasında Basit Doğrusal Regresyon Analizi yöntemi yardımıyla bir bağlantı kurularak, bu bağlantı üzerinden kestirilen değerler yorumlanabilir ve $Y = a + bX + e$ bağıntısı için b’nin 1’e; e’nin 0’a yakınsaması durumunda gözlenen ve kestirilen değerlerin birbirlerine önemli ölçüde benzediği sonucu çıkarılabilir. Basit Doğrusal Regresyon Analizi sonuçları Tablo 5’de sunulmuştur.

Tablo 5. Regresyon Analizi Sonuçları

değişken	B	S.Hata B	B	t	P
----------	---	----------	---	---	---

sabit	12,846	1,348		9,527	.00
gözlenen	.81	.019	.911	43,604	.00
$R^2 = .83$					

Tablo 5’deki sonuçlardan hareketle, kestirilen başarı ölçüleri = 12,846 + 0,81.gözlenen başarı ölçüleri + 0,019 şeklinde bir bağıntı elde etmek mümkündür. Bu bağıntıdaki 0,81 değerinin 1’e ve 0,019 değerinin 0’a yakınsaklığı değerlendirildiğinde ($p < .05$), kestirilen değerlerin gözlenen değerleri yordama düzeyinin yüksek olduğu görüşü ortaya çıkmaktadır. Kestirilen ve gözlenen başarı ölçüleri arasındaki korelasyon değerinin(β) 0,911 olması ($p < .05$), bu değerin 0,7 ile 1 arasında olması ilişkinin pozitif yönlü yüksek düzeyde olduğuna karşılık gelmektedir (Büyüköztürk, 2013, 32), bu iki değişken arasındaki ilişkinin pozitif yönde ve yüksek düzeyde olduğu anlamına gelmektedir. Ayrıca, kestirilen başarı ölçülerine ilişkin değişimin % 83’ünün ($R^2 = .83$) gözlenen başarı ölçüleri tarafından açıklandığı görülmektedir.

Kestirilen ölçüler ile gözlenen ölçülerin bir arada gösterilmesi amacıyla oluşturulan grafiksel gösterim Şekil 4’de verilmiştir.

Şekil 4. Gözlenen ve Kestirilen Başarı Ölçülerinin Grafiksel Gösterimi

Şekil 4 ile gözlenen başarı ölçüleri ile kestirilen başarı ölçülerinin ne düzeyde benzerlik gösterdiği grafiksel gösterimle açıklanmaya çalışılmıştır.

Gözlenen ve kestirilen başarı ölçülerinin başarı durumlarını belirleyen kategorik normlarla ifade edilmesi amacıyla, YYÜ Ölçme ve Değerlendirme Esasları Yönergesi (YYÜ, 2013) 'ne göre üniversitenin başarı kriteri olan 60 değeri esas alınmış; 60 ve üzerindeki değerler 'başarılı', 60'ın altındaki değerler 'başarısız' olarak kategorik formata dönüştürülmüştür. Gözlenen ve kestirilen değerleri esas alan başarı durumlarıyla ilgili bilgiler Tablo 6 ile sunulmuştur.

Tablo 6. Başarı Durumlarına Ait Sınıflama (Kontenjans) Tablosu

			Kestirilen		
			Başarısız	Başarılı	Toplam
Gözlenen	Başarısız	n	32	2	34
		%	8,2	0,5	8,7
	Başarılı	n	9	349	358
		%	2,3	89	91,3
	Toplam	n	41	351	392
		%	10,5	89,5	100
$X^2 = 278,217$ sd = 1 p = .00					

Gözlenen ve kestirilen başarı ölçülerinin kategorik formata dönüştürülmesiyle, başarı durumları Tablo 6'da gösterildiği gibi belirlenmiştir. Kestirilen başarı ölçülerine göre 41 başarısız, 351 başarılı; gözlenen başarı ölçülerine göre 34 başarısız, 358 başarılı değer elde edilmiştir. Gözlenen ve kestirilen başarı durumları karşılaştırıldığında, gözlenen ölçülere göre başarısızken kestirilen ölçülere göre başarılı olan 2 değer belirlenmiş ve hata yüzdesi 0,5 olarak saptanmıştır. Gözlenen ölçülere göre başarılıyken kestirilen ölçülere göre başarısız olan 9 değer belirlenmiş ve hata yüzdesi 2,3 olarak saptanmıştır. Genel anlamda 11 değer hatalı olarak belirlenmiş ve bu hata oranı % 2,8 olarak tespit edilmiştir, dolayısıyla doğru sınıflama yüzdesi % 97,2 olarak elde edilmiştir. Gözlenen ve kestirilen başarı durumları arasındaki ilişkinin

anlamlılığı Ki-kare istatistiği ile araştırılmış ve elde edilen sonuçlara göre; $X^2 = 278,217$ ($p<.05$) değeri gereğince, aradaki bu ilişkinin anlamlı olduğu ortaya çıkmıştır.

Tartışma, Sonuç ve Öneriler

Tartışma

Günümüzün önemli ve yaygın kullanılan uygulamaları arasında kabul edilen (Deperlioğlu & Köse, 2011; Elmas, 2003, 22; Öztemel, 2003, 13) yapay zekâ bilimi ve özellikle YSA'nın; sınıflama, modelleme, kestirim (tahmin), optimizasyon gibi önemli alanlarda geçerli ve başarılı sonuçlar elde ettiği yapılan çalışmalarla (Toprak, 2017; Tezbaşaran, 2016; Bahadır, 2016; Kuzmanovic, Jevric, Gajic, Kovacevic, Vasiljevic, Kecojevic & İvanovic, 2015; Bou-Rabee, Suliaman, Choe, Han, Saaed & Marati, 2015; Tekin, 2014; Şevik, Aktaş, Özdemir ve Doğan, 2014; Kasaplı, 2014; Rahmani & Aprilianto, 2014; Turhan vd., 2013; Musso, Kyndt, Cascallar & Dochy, 2013; Ötkün ve Karlık, 2013; Ataseven, 2013; Koç, 2012; Çırak, 2012; Tepahan, 2011; Açıkbaz, Kaypmaz ve Söylemez, 2010; Lee, 2010; Burmaoğlu, 2009; Helhel, 2009; Asilkan ve Irmak, 2009; Oladokun vd., 2008; Aslan, 2008; Yılmaz, Güneş ve Aksu, 2007; Caner ve Üstün, 2006; Ocakoğlu, 2006; Erdem ve Uzun, 2005; Naik & Rogathan, 2004; Çikoğlu, Temurtaş ve Yumurcak, 2004) ortaya çıkmıştır.

Çalışmada, öğrencilerin öğretim dönemi sonunda elde edecekleri başarı ölçüleri (AGNO değerleri) YSA aracılığıyla geliştirilen tahmin modeli ile kestirilmiş ve modelinin kestirdiği başarı ölçüleri ile gözlenen başarı ölçüleri arasındaki ilişkiyi ifade eden korelasyon değeri 0,911 olarak belirlenmiştir. Benzer şekilde yapılan araştırmalara bakıldığında, Rahmani & Aprilianto'nun (2014) öğrencilerin mezuniyet notu ve yılını kestirdikleri çalışmalarında elde ettikleri sonuçlar ile gözlenen sonuçlar arasındaki korelasyon değerini 0,99; Turhan vd.'nin (2013) tıp fakültesi öğrencilerinin komite sınavları ve bir takım değişkenler aracılığıyla YSA ile kestirdikleri final notları ile gözlenen notlar arasındaki korelasyon değerini 0,93;

Musso vd. (2013) dikkat, hafıza, öğrenme stratejileri gibi bilişsel ve çeşitli demografik ve çevresel unsurları esas alarak öğrencilerin akademik performanslarını sınıflandırmış ve modelin ürettiği sürekli puan değerleri ile gözlenen değerler arasındaki korelasyon değerini 0,86 olarak tespit etmişlerdir. Diğer taraftan, Aybek (2016), Anadolu Üniversitesi Açık Öğretim Sistemi'nde mevcut olan Temel Bilgi Teknolojisi dersini alan öğrencilerin dönem sonu puanını YSA ile kestirmiş ve kestirilen puanlar ile gözlenen puanlar arasındaki korelasyonu düşük olarak ifade etmiştir.

Kestirilen başarı ölçüleri ve gözlenen başarı ölçüleri, üniversitenin başarı kriteri olan 60 değerine göre; 60 ve üzeri değerlerin başarılı, 60'dan küçük değerlerin başarısız olarak değerlendirilip kategorik formata dönüştürülmesinden sonra sınıflama (kontenjans) tablosu yardımıyla karşılaştırılmıştır. Kestirilen başarı durumları % 97,2 oranında doğru sınıflama derecesi göstermiştir. Girdi değişkenleri aynı olmasa da çıktı değişkeninin akademik başarı olduğu YSA ile yapılan benzer çalışmalarda sınıflandırmaların doğruluk oranı, Bahadır'ın (2016) yaptığı çalışmada % 93,02; Tekin'in (2014) yaptığı çalışmada % 93,76; Musso vd.'nin (2013) yaptığı çalışmada üç grup için sırasıyla % 100, % 100 ve % 87; Çırak'ın (2012) yaptığı çalışmada % 70,16; Oladokun vd.'nin (2008) yaptığı çalışmada % 74, ve Naik & Ragothaman'ın (2004) yaptığı çalışmada % 89,13 olarak belirlenmiştir. Tepehan'ın (2011) PISA sonuçlarınca elde edilen öğrenci başarılarına göre, YSA ile lojistik regresyon yöntemlerinin performanslarını karşılaştırdığı çalışmasında YSA daha başarılı sınıflama performansı göstermiştir. Ayrıca Lee'nin (2010), tasarım öğrencilerinin birinci sınıfta aldığı derslerle ilişkilendirilmesi suretiyle, YSA ile üst sınıflarda aldığı üç majör dersi kestirim başarıları birinci ders için % 91,27, ikinci ders için % 93,54 ve üçüncü ders için % 94,94 olmuştur. Bu çalışmada olduğu gibi ilgili çalışmalarda da YSA'nın öğrenci başarılarını doğru sınıflama başarısının geçerli ve yüksek olduğu anlaşılmaktadır.

Sonuç

Çalışmada, 3. sınıf öğrenci verileri kullanılarak geliştirilen, öğrencilerin dönem sonu başarı ölçülerini kestiren YSA modeli; 1 girdi, 1 ara ve 1 çıktı katmanından, girdi katmanında 99, ara katmanda 3 ve çıktı katmanında 1 olmak üzere toplam 103 hücreden meydana gelen Çok Katmanlı Perceptron (MLP) Ağı ile oluşturulmuştur. Veri akışının sağlanmasında, ağın ara katmanlarında Sigmoid, çıktı katmanında ise Doğrusal Fonksiyon kullanılmıştır. Hata fonksiyonu olarak da Hata Kareler Toplamı algoritması kullanılmıştır. Modelin eğitilmesi; 657 üçüncü sınıf öğrencisi verilerinin % 54 oranıyla 355 eğitim seti, % 29,1 oranıyla 191 test seti ve % 16,9 oranıyla 111 geçerlilik seti şeklinde üç gruba ayrılarak gerçekleştirilmiştir. 2. sınıf öğrencilerine ait 17 girdi değişkeninin geliştirilen bu modele tanıtılmasıyla, öğrencilerin devam etmekte olan söz konusu öğretim dönemine ait dönem sonu başarı ölçüleri kestirilmiştir.

Gözlenen ve kestirilen ölçülerin ne düzeyde benzerlik gösterdiğini ortaya koymak amacıyla çeşitli analiz çalışmaları yapılmıştır. Bu çalışmalardan ilki, iki veri grubunun normal dağılım göstermesi esasıyla Basit Doğrusal Regresyon Analizi olmuştur. Regresyon modelinin yordanan değişkeni kestirilen başarı ölçüleri olup, yordayıcı değişkeni gözlenen başarı ölçüleri olmuştur. $Y = a + bX + e$ regresyon modeli için, b değerinin 1'e ve e değerinin 0'a yakınsaması yordayıcı özelliğin yüksek düzeyde olduğu anlamı taşımaktadır. Kestirilen başarı ölçüleri = $12,846 + 0,81 \cdot \text{gözlenen başarı ölçüleri} + 0,019$ bağıntısıyla elde edilen modeldeki 0,81 değerinin 1'e ve 0,019 değerinin 0'a yakınlığı doğrultusunda yordayıcılığın yüksek düzeyde olduğu savunulabilmektedir. Ayrıca gözlenen ölçüler ile kestirilen ölçüler arasındaki korelasyon değerinin 0,911 olması bu ölçüler arasındaki ilişkinin pozitif yönlü yüksek düzeyde olduğu anlamı taşımaktadır. Kestirilen ölçülerdeki değişkenliğin % 83'ünün gözlenen ölçüler tarafından kaynaklanması bu iki değişkenin birbirlerine önemli derecede benzedikleri anlamına gelmektedir.

Gözlenen ve kestirilen başarı ölçüleri, sınıflandırma başarısının test edilmesi amacıyla kategorik türe dönüştürülmüştür. Bu dönüşüm, üniversitenin geçme notu olan 60 değerine göre; 60 ve üzeri değerlerin başarılı, 60'ın altındaki değerlerin başarısız olarak değerlendirilmesiyle gerçekleşmiş ve başarı durumları olarak adlandırılmıştır. Kestirilen başarı durumları ile gözlenen başarı durumları sınıflama (kontenjans) tabloları aracılığıyla karşılaştırılmış ve sonuç olarak, gözlenen ölçülere göre başarısızken kestirilen ölçülere göre başarılı olan 2 değer belirlenmiş ve hata yüzdesi 0,5 olarak saptanmıştır. Gözlenen ölçülere göre başarılıyken kestirilen ölçülere göre başarısız olan 9 değer belirlenmiş ve hata yüzdesi 2,3 olarak saptanmıştır. Genel anlamda ise 11 değer hatalı olarak belirlenmiş ve bu hata payı % 2,8 olarak ortaya çıkmıştır. Yani gözlenen ve kestirilen başarı durumlarının başarılı ve başarısız olarak sınıflandırılmasındaki doğruluk oranı % 97,2 olmuştur.

Öneriler

Çalışmada temas edildiği üzere kestirilen geçerli sonuçlar aracılığıyla; verimli eğitim yönetimi, başarıyı olumlu yönde etkileme, eksik ve ihtiyaçların belirlenmesi, öğrenmelerin iyileştirilmesi gibi durumların süreç içinde görülüp bu durumlara süreç devam ederken müdahale edilmesinin, eğitimin gelişimine önemli ölçüde katkı sağlayacağı düşüncesinden hareketle; eğitim kurumlarının araştırmada esas alınan yöntemden yararlanabileceği düşünülmektedir. Bu sayede, yöntemin eğitim programları ve sistemlerine adapte edilmesiyle program ve sistemlerden elde edilmek istenen dönütlere daha erken sürelerde ulaşılabileceği ve gerekli düzenlemelerin erken sürelerde yapılabileceği düşünülmekte ve önerilmektedir.

Öğrenci başarı ölçüleri ve başarı durumlarını erken kestirmek adına kullanılan YSA ile tahmin modelinin girdi değişkenlerinin amaç doğrultusunda artırılması ve kullanılacak verilerin sistemsal tabanlar üzerinden elde edilmesi gibi durumlar, kestirim gücü açısından daha iyi ve başarılı sonuçlar vereceği düşünülmektedir.

Kestirim amaçlı geliştirilen YSA modelinin programlama tekniğiyle harmanlanıp, kolay ve kullanışlı bilgisayar programları haline dönüştürülmesinin, başarı öngörüsünü erken ve başarılı bir şekilde ilgililere sunacağı ve öğrenci başarılarını konu alan çalışmaları daha ileri noktalara taşıyacağı düşünülmektedir.

Öğrencilerin uzak gelecekteki başarı durumlarını kestiren modelin geliştirilmesiyle, gelecekte şekillenecek değişimleri gözlemleme, bu değişimlerin öğrencilerin başarılarını nasıl etkileyeceği, hangi gelişmelerin hangi etkilerle sonuçlanacağı gibi önemli hususların belirlenebileceği ve bu sayede öğrencilerin uzak gelecekteki başarılarının müdahale edilebilir seviyeye taşınabileceği düşünülmektedir.

Makalenin Bilimdeki Konumu (Yeri)

Eğitim bilimleri alanında yapılmış olan bu çalışma, öğrenci başarısını konu alan tüm eğitim alanlarıyla ilişkilendirilebilir.

Makalenin Bilimdeki Özgünlüğü

Öğrencilerin başarı ölçüleri dolayısıyla akademik başarılarının erken kestirilmesine yönelik gerçekleştirilen bu çalışma, Yapay Sinir Ağları(YSA) aracılığıyla oluşturulan bir modelleme ve modelin ürettiği değerlerin benzerliğinin araştırılması niteliğindedir. Bu anlamda, yapılacak uygun erken kestirimlerin öğretim sürecini izleme, düzeltme, dönüt verme, müdahale etme gibi önemli unsurları süreç içerisinde uygulama fırsatı sunacağı düşünülmektedir. Ayrıca diğer bir yönüyle de, öğrenci başarılarını etkilediği ya da etkileyeceği düşünülen değişkenlerin bu amaç doğrultusunda test edilmesi imkanı sunma özelliği göstermektedir.

Kaynaklar

- Açıkbaş, S., Kaypmaz, A. ve Söylemez, M. T. (2010). Raylı toplu taşıma sistemlerinde boşta gitme noktalarının optimizasyonu. *İstanbul Teknik Üniversitesi Dergisi D Mühendislik*, 9(1), 3-14.
- Anıl, D. (2009). Uluslararası öğrenci başarılarını değerlendirme programı (PISA)'nda Türkiye'deki öğrencilerin fen bilimleri başarılarını etkileyen faktörler. *Eğitim ve Bilim Dergisi*, 152(34), 87-100.
- Asilkan, Ö. ve Irmak, S. (2009). İkinci el otomobillerin gelecekteki fiyatlarının yapay sinir ağları ile tahmin edilmesi. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 14(2), 375-395.
- Aslan, M. (2008). *Eymir Gölü'nde su kalitesinin yapay sinir ağları ve adaptif sinirsel bulanık ilişkisel sistem ile modellenmesi*. Yayınlanmış yüksek lisans tezi, Fen Bilimleri Enstitüsü, Orta Doğu Teknik Üniversitesi, Ankara.
- Aslantaş, H. İ., Özkan, M. ve Külekçi, E. (2012). Eğitim fakültesi öğrencilerinin akademik başarı düzeylerinin bazı demografik değişkenler açısından incelenmesi. *Elektronik Sosyal Bilimler Dergisi*, 11(39), 395-407.
- Atan, M., Göksel, A. ve Karpat, G. (Ekim, 2002). *Üniversite öğrencilerinin başarılarını etkileyen faktörlerin çok değişkenli istatistik teknikleri ile tespiti*. Sözlü bildiri, XI. Eğitim Bilimleri Kongresi, Yakındoğu Üniversitesi, Kıbrıs.
- Ataseven, B. (2013). Yapay sinir ağları ile öngörü modellemesi. *Öneri Dergisi*, 10(39), 101-115. doi:<http://dx.doi.org/10.14783/od.v10i39.1012000311>
- Aybek, H. S. Y. (2016). *Öğrenci başarısının yapay sinir ağları ile kestirilmesi: Anadolu Üniversitesi Açıköğretim Sistemi örneği*. Yayınlanmamış yüksek lisans tezi, Sosyal Bilimler Enstitüsü, Anadolu Üniversitesi, Eskişehir.
- Bahadır, E. (2016). Using neural network and logistic regression analysis to predict prospective mathematics teachers' academic success upon entering graduate education. *Educational Sciences: Theory & Practice*, 16, 943-964.
- Baş, N. (2006). *Yapay sinir ağları yaklaşımı ve bir uygulama*. Yayınlanmış yüksek lisans tezi, Fen Bilimleri Enstitüsü, Mimar Sinan Üniversitesi, İstanbul.

- Bou-Rabee, M.A., Suliaman, S.A., Choe, G., Han, D., Saaed, T. & Marati, S. (2015). Characteristics of solar energy radiation on typical summer and winter days in Kuwait. *International Journal of Automotive and Mechanical Engineering*, 12(1), 2944-2954.
- Burmaoğlu, S. (2009). *Birleşmiş milletler kalkınma programı beşeri kalkınma verilerini kullanarak, diskriminant analizi, lojistik regresyon analizi ve yapay sinir ağlarının sınıflandırma başarılarının değerlendirilmesi*. Yayınlanmış doktora tezi, Sosyal Bilimler Enstitüsü, Atatürk Üniversitesi, Erzurum.
- Büyüköztürk, Ş. (2013). *Sosyal bilimler için veri analizi el kitabı*. Ankara: Pegem Akademi Yayınları.
- Büyüköztürk, Ş. ve Deryakulu, D. (2002). Bilgisayar ve öğretim teknolojileri öğretmenliği ile sınıf öğretmenliği programı öğrencilerinin akademik başarılarını etkileyen faktörler. *Kuram ve Uygulamada Eğitim Yönetimi Dergisi*, 30, 187-204.
- Büyüköztürk, Ş., Çakmak, E. K., Akgün, Ö. E., Karadeniz, Ş. ve Demirel, F. (2014). *Bilimsel araştırma yöntemleri*. Ankara: Pegem Akademi Yayınları.
- Caner, M. ve Üstün, S.V. (2006). Yapay sinir ağları ile konuşmacı kimliğini tanıma uygulaması. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 12(2), 279-284.
- Çırak, G. (2012). *Yüksek öğretimde öğrenci başarılarının sınıflandırılmasında yapay sinir ağları ve lojistik regresyon yöntemlerinin kullanılması*. Yayınlanmış yüksek lisans tezi, Eğitim Bilimleri Enstitüsü, Ankara Üniversitesi, Ankara.
- Çikoğlu, S., Temurtaş, F. ve Yumurcak, N. (2004). Yapay sinir ağları ile yapılan imza tanıma eşikleme etkisi. *Teknoloji Dergisi*, 7(1), 151-160.
- 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.
- Demirtaşlı, R.N. (Ed.). (2014). *Eğitimde ölçme ve değerlendirme*. Ankara: Edge Akademi.
- Deperlioğlu, O. & Köse, U. (2011). An educational tool for artificial neural networks. *Computers and Electrical Engineering*, 37, 392-402.
- Doğan, A. (2002). *Yapay zekâ*. İstanbul: Kariyer Yayıncılık.
- Efe, M. Ö. ve Kaynak, O. (2000). *Yapay sinir ağları ve uygulamaları*. İstanbul: Boğaziçi Üniversitesi Yayınları.
- Ekşioğlu, S. (2005). Okul türlerine göre lise öğrencilerinin ÖSS başarılarını etkileyen zihin dışı faktörler. *Sakarya Üniversitesi Eğitim Fakültesi Dergisi*, 10.

<<http://dergipark.ulakbim.gov.tr/sakaefd/article/view/5000003706>> adresinden erişilmiştir. (24.07.2017).

- Elmas, Ç. (2003). *Yapay sinir ağları*. Ankara. Seçkin Yayıncılık.
- Erdem, O.A. ve Uzun E. (2005). Yapay sinir ağları ile Türkçe times new roman, arıal ve el yazısı karakterlerini tanıma. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 20(1), 13-19.
- Gökalp, M. (2006). Üniversite öğrencilerinin başarılarını etkileyen okul-içi faktörler. *Ondokuz Mayıs Üniversitesi Eğitim Fakültesi Dergisi*, 22, 72-81.
- Gürsakil, S. (2012). Pisa 2009 öğrenci başarı düzeylerinin etkileyen faktörlerin değerlendirilmesi. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 17(1), 441-452.
- Haton, J.P., ve Haton, M.C.(1991). *Yapay zekâ*. (Çev. A. Ekmekçi ve A. Türker). İstanbul: İletişim Yayınları (Orijinal Çalışmanın Yayın Tarihi 1989).
- Helhel, Y. (2009). *Makroekonomik değişkenler ve döviz kuru ilişkisi: yapay sinir ağı ve VAR yaklaşımları ile öngörü modellemesi*. Yayınlanmış doktora tezi, Sosyal Bilimler Enstitüsü, Süleyman Demirel Üniversitesi, Isparta.
- Kalkınma Bakanlığı. (2013). *İllerin ve bölgelerin sosyo-ekonomik gelişmişlik sıralaması araştırması (SEGE-2011)*. <https://http://www.kalkinma.gov.tr> internet adresinden erişilmiştir (13.10.2015).
- Karip, E. (Ed.). (2012). *Ölçme ve değerlendirme*. Ankara: Pegem Akademi Yayıncılık.
- Kasaplı, K. (2014). *İçme suyu şebekelerinde maliyet tahmini amacıyla yapay sinir ağları kullanımı*. Yayınlanmış yüksek lisans tezi, Fen Bilimleri Enstitüsü, İstanbul Teknik Üniversitesi, İstanbul.
- Koç, G. (2012). *Tünel sistemlerinde araç kaynaklı hava hızlarının yapay sinir ağları kullanılarak modellenmesi*. Yayınlanmış doktora tezi, Fen Bilimleri Enstitüsü, Orta Doğu Teknik Üniversitesi, Ankara.
- Kuzmanovic, S.P., Jevric, L., Gajic, J.S., Kovacevic, S., Vasiljevic, I., Kecojevic, I. & Ivanovic, E. (2015). Artificial neural network approach to modelling of metal contents in different types of chocolates. *Acta Chimica Slovenica*, 62, 190-195.
- Lee, Y.-J. (2010). Neurel network based approach for predicting learning effect in desing students. *International Journal of Organizational Innovation*, 1, 250-270.

- Memduhoğlu, H. B. ve Tanhan, F. (2013). Üniversite öğrencilerinin akademik başarılarını etkileyen örgütsel faktörler ölçeğinin geçerlilik ve güvenirlik çalışması. *Yüzüncü Yıl Üniversitesi Eğitim Fakültesi Dergisi*, 1, 106-124.
- Metin, M. (2013). Öğrencilerin seviye belirleme sınavındaki başarısına etki eden unsurların farklı değişkenler açısından incelenmesi. *Ahi Evran Üniversitesi Kırşehir Eğitim Fakültesi Dergisi*, 14(1), 67-83.
- Musso, M.F., Kyndt, E., Cascallar, E.C. & Dochy F. (2013). Predicting general academic performance and identifying the differential contribution of participating variables using artificial neural Networks. *Frontline Learning Research*, 1, 42-71.
- Naik, B. & Ragothaman, S. (2004). Using neural networks to predict MBA student success. *College Student Journal*, 38(1).
- Ocakoğlu, G. (2006). *Lojistik regresyon analizi ve yapay sinir ağları tekniklerinin sınıflama özelliklerinin karşılaştırılması ve bir uygulama*. Yayınlanmış yüksek lisans tezi, Sağlık Bilimleri Enstitüsü, Uludağ Üniversitesi, Bursa.
- Oladokun, V.O., Adebajo, A.T. & Charles-Owabo, 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.
- Örkcü, H.H. (2009). *Ayrırma analizine matematiksel programlama ve yapay sinir ağları yaklaşımları*. Yayınlanmış doktora tezi, Fen Bilimleri Enstitüsü, Gazi Üniversitesi, Ankara.
- Ötkün, A. ve Karlık, B. (Eylül, 2013). *YSA ve pencere ortalamaları kullanılarak yüz tanıma sistemi*. Sözlü bildiri, *Otomatik Kontrol Ulusal Toplantısı*, İnönü Üniversitesi, Malatya.
- Öztemel, E. (2003). *Yapay sinir ağları*. İstanbul: Papatya Yayıncılık.
- Peker, R. (2003). Uludağ üniversitesi eğitim fakültesi beden eğitimi ve spor bölümü öğrencilerinin genel akademik başarılarının bazı değişkenlere göre incelenmesi. *Uludağ Üniversitesi Eğitim Fakültesi Dergisi*, 17(1), 161-171.
- Rahmani, B. & Aprilianto, H. (2014). Early model of student's graduation prediction based on neural network. *Telkomnika (Telecommunication Computing Electronics and Controls)*, 12(2), 465-474.
- Saraç, T. (2004). *Yapay sinir ağları*. Gazi Üniversitesi: Basılmamış Seminer Projesi.
- Savaş, E., Taş, S. & Duru, A. (2010). Factors affecting students' achievement in mathematics. *Inonu University Journal of The Faculty of Education*, 11(1), 113-132.

- Sayın, A. ve Gelbal, S. (2014). Başarıyı etkileyen faktörlerin önem derecelerinin ardışık aralıklar yöntemiyle ölçeklenmesi. *Amasya Üniversitesi Eğitim Fakültesi Dergisi*, 3(1), 1-26.
- Seven, M. A. ve Engin, A. O. (2008). Öğrenmeyi etkileyen faktörler. *Atatürk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 12(2), 189-212.
- Şeker, R., Çınar, D. ve Özkaya, A. (Haziran, 2004). Çevresel faktörlerin üniversite öğrencilerinin başarı düzeyine etkileri. Sözlü bildiri, XIII. Ulusal Eğitim Bilimleri Kurultayı, İnönü Üniversitesi, Malatya.
- Şen, Z. (2004). *Yapay sinir ağları ilkeleri*. İstanbul: Su Vakfı Yayınları.
- Şevik, S., Aktaş, M., Özdemir, M.B. ve Doğan, H. (2014). Güneş destekli ısı pompalı bir kurutucuda mantarın koruma davranışlarının yapay sinir ağı kullanılarak modellenmesi. *Tarım Bilimleri Dergisi*, 20, 187-202.
- Taşgetiren, M.F. (2005). Çok katmanlı yapay sinir ağları. http://bilim.ficicilar.name.tr/sayfa/Fatih_Tasgetiren-Cok_Katmanli_Yapay_Sinir_Aglari.html internet adresinden erişilmiştir (24.01.2016).
- Tekin, A. (2014). Early prediction of students' grade point averages at graduation: A data mining approach. *Eurasian Journal of Educational Research*, 54, 207-226.
- Teknosektör. <http://teknosektor.com/2015/06/03/yapay-sinir-aglari-beyin-simulasyonu/> internet adresinden erişilmiştir (06.01.2016).
- Tepehan, T. (2011). *PISA başarılarının yordanmasında yapay sinir ağı ve lojistik regresyon modeli performanslarının karşılaştırılması*. Yayınlanmış doktora tezi, Eğitim Bilimleri Enstitüsü, Hacettepe Üniversitesi, Ankara.
- Tezbaşaran, E. (2016). *Temel bileşenler analizi ve yapay sinir ağı modellerinin ölçek geliştirme sürecinde kullanılabilirliğinin incelenmesi*. Yayınlanmış doktora tezi, Eğitim Bilimleri Enstitüsü, Mersin Üniversitesi, Mersin.
- Toprak, E. (2017). *Yapay sinir ağı, karar ağaçları ve ayırma analizi ile PISA 2012 matematik başarılarının sınıflandırma performanslarının karşılaştırılması*. Yayınlanmamış doktora tezi, Eğitim Bilimleri Enstitüsü, Hacettepe Üniversitesi, Ankara.
- Turgut, M.F. ve Baykul, Yaşar. (2013). *Eğitimde ölçme ve değerlendirme*. Ankara: Pegem Akademi.
- Turhan, K., Kurt B. & Engin, Y.Z. (2013). Estimation of student success with artificial neural networks. *Education and Science*, 170(38), 112-120.

- Yılmaz, Ş., Güneş, M. ve Aksu, M. (2007). Rüzgar enerjisi ile tahrik edilen bilezikli asenkron jeneratörün yapay sinir ağları ile denetlenmesi. *Makine Teknolojileri Elektronik Dergisi*, 1, 15-24.
- Yüksel, G. ve Sezgin, F. (2008). Üniversite öğrencilerinin başarılarını etkileyen zihinsel olmayan faktörler; Gazi Üniversitesi örneği. *Milli Eğitim Dergisi*, 179, 66-81.
- YYÜ. (2013). *Ölçme ve değerlendirme esasları yönergesi*. <https://www.yyu.edu.tr> internet adresinden erişilmiştir (12.03.2016).

Summary

Problem Statement

Artificial neural networks are network structures in which the hierarchical phenomena interact with real life in parallel and interconnected networks, in a similar way with biological nervous systems (Kohonen, 1987; Akt: Taşgetiren, 2005). The diversity of artificial neural networks in terms of structure and learning gives different and lots of opportunities to researcher for usage (Efe ve Kaynak, 2000, 3). Education of individuals has turned into a state of provision of learning in different fields by supporting with various environmental and organizational structures from birth (Seven ve Engin, 2008; Gökalp, 2006). As a product of changes in people, It is possible to show behaviors which individuals have (Seven ve Engin, 2008). However, academic success is defined as the skills or knowledge gained by the lectures as the expression of test scores, or notes which are the evaluation of teacher, or both (Carter ve Good, 1973; Akt: Memduhoğlu ve Tanhan, 2013). The number forming this universe is approximately 17000 and the number of sufficient samples for the research is determined as 380 (Büyüköztürk, Çakmak, Akgün, Karadeniz and Demirel, 2014, 95). In the study, the data of the 2nd and 3rd grade students were used in the prediction model formed by artificial neural networks on the basis of objective sampling. Purpose-based sampling is a process that enables

research to be conducted by selecting specific cases that have specific characteristics and which carry rich information of the desired information depending on the purpose of the study (Büyüköztürk et al., 2014, 90).

Findings and Discussions

Findings and Comments on the First Sub-problem: The most important variable in the model was "second term end AGNO" with a share of 45.1%. The value of "the second term final achievement measure (AGNO)" is followed by "department" with 6.7%, by "mothers education status" with 5.9%, and the "scored score type" with 5.6%.

"Faculty" and "number of siblings" were 4.1%; "mother and father's co-existence status" variable 4%; the "educational status of the father" variable was 3.9%; "score of OSYM in which the division was placed" variable is 3.6%; "discretionary willingness to settle" and "age" variables were 3.1%; "graduated high school type" variable 3%; "average monthly income of the family" variable was 2.6%; "high school diploma grade" variable 2,4%; the "long-term residence" variable was 1.6%; "sex" variables were 0.7% and variability of "living with the family" were included in the model with a significance level of 0,6%.

Findings and Interpretations on the Second Sub-problem: According to the predicted measurement of achievement 41 unsuccessful 351 successful were obtained while 34 unsuccessful and 358 successful values according to measurement of observed achievement were obtained. When the observed and predicted successes were compared, 2 values which are unsatisfactory according to observed measurements, but satisfactory according to predicted measurements were stated, and the percentage of error was determined as 0.5. Nine values which were successful according to the observed measurements, but unsuccessful with respect

to the predicted measurements was determined, and the percentage of error was indicated as 2.3. In general, 11 values were determined as erroneously and this error rate was 2.8%, so the correct classification percentage was 97.2%. The significance of the relationship between observed and predicted success cases was investigated with Chi-square statistic and according to the obtained, this relationship is meaningful due to the value which is $X^2 = 278,217$ ($p < .05$).

Conclusions and Recommendations

In the study, students' success levels which will be obtained at the end of the teaching period (AGNO values) was predicted with prediction model which is improved with artificial neural networks, and correlation value which shows the relationship between success measurements predicted by the model and observed success measurement was determined as 0,911. By means of the estimated results as indicated in the study; while teaching term continues, different situations such as, efficient education management, influencing success in positive direction, determining missed points and needs, improvement of learning can be observed, and people can be interfered these kind of situations, so the method that is based on research can be used by educational institutions because of its benefit for the improvement of the education.

Key words: Artificial neural networks, student success, estimation