

Öğrencinin Akademik Başarısının Yapay Sinir Ağları ile Tahmin Edilmesi

Erol Özçekic¹, Ümit Öztürk², Ediz Şaykol³

¹Beykent Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim dalı, İstanbul

²Beykent Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim dalı, İstanbul

³Beykent Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim dalı, İstanbul

erolozcekic@balikesir.edu.tr, ozturk.u@hotmail.com, ediz.saykol@beykent.edu.tr

Özet: Eğitim konusu tüm toplumların önem verdiği hassas bir konudur. Bir ülkede eğitilmiş bireylerin artması o ülkeye önemli sosyo-ekonomik katkılar sağlar. Ayrıca eğitim meselesi her zaman iyileştirilmeye ihtiyaç duyar ve yenilikleri adapte etmek zorundadır. Tam bu noktada öğrencilerin akademik başarısını arttırmak eğitim kalitesine direkt olumlu etki yapacaktır. Bu çalışmada öğrencilerin akademik başarılarını önceden tahmin etmeye yönelik bir sınıflandırma yapılmıştır. Öğrencinin akademik başarısının öngörülmesiyle beraber gerekli düzenlemeler önceden yapılabilir. Çalışma, Knime açık kaynak kodlu veri analizi aracı üzerinde Yapay Sinir Ağları kullanılarak gerçekleştirilmiştir. Gerekli bulgular ve bu bulguların üzerinden tartışma ve sonuçlar verilmiştir.

Anahtar Sözcükler: Knime, Yapay Sinir Ağları, Sınıflandırma.

Abstract: Education is a delicate issue to which all societies attach importance. In one country, the increment of educated people give important socio-economics contributions. Furthermore, education issue always need to be enhanced and should adapt changes. At that point, the raise of academic success of students make positive effect on education quality. At this work, a classification which estimates the academic success of students is made. By this way, necessary arrangements can be made to prevent unsuccess. The work is carried out on Knime that is open source data analytics tool and Artificial Neural Network algorithm is used for it. The necessary findings and related discussion and results are given.

1. Giriş

Küreselleşme son yıllarda adını çokça duyduğumuz bir kavramdır ve oldukça geniş bir alanda etkinliği mevcuttur. İlk ortaya atılışında ekonomik içerikli manalar taşımaktaydı [1]. Toplumlar deneyimlerini dahi ortak hale getirmişler ve birçok faaliyetleri ortaklaşa yapmaya başlamışlardır. Bu etkileşim içerisinde seyahat, finans, ticaret, iletişim, meslekler ve hatta müzik dahi bulunmaktadır [2]. Buna göre aslında küreselleşme ekonominin yanı sıra siyasal, kültürel bütünleşme ve görüşlerin, fikirlerin ve teknolojinin küresel düzeyde kullanılması, dünyanın tek bir pazar haline gelmesidir [3]. Bununla beraber, rekabet kavramı da ön planda tutulur. Bu da ülkelerin ulusal politikalarını rakiplerine göre daha üstün kılmak üzere gereğini yapmasını teşvik eder. Toplumların bu süreci en verimli şekilde götürebilmesi için iyi yetişmiş ve yeniliklere

uyum sağlayabilecek bireylere ihtiyacı vardır. Bu noktada eğitimin rolü kritiktir [4].

Eğitim, bireylerin kasıtlı olarak kendi yaşamlarında istenen değişimleri kazanması süreci manası taşır [5]. Gerek küresel koşullara ayak uydurabilmek gerekse istenen yaşam koşullarını sağlayabilmek o toplumda yaşayan insanın geçerli ve güvenilir davranışlar kazanmasıyla mümkündür. Bu insan yuva kuracak, üretim yapacak, yol, baraj inşa edecek, fabrika işletecek ve devleti yönetecektir. Tüm bunları yapabilmesi o insanın problem çözücü bilgi ve becerilerle donatılması ile mümkün olabilir. Bunu da eğitim sağlayabilir [6].

Teknoloji ve bilimin gelişmesi ülkelerin siyasi ve ekonomik yönden gelişimini ve değişimini sağlamıştır. Bu paralelde rekabet hızla artmış yeni oluşumlar ve teknolojik atılımlar ortaya çıkmıştır. Bu durum eğitim konusunu da etkilemiştir [7]. Bilim ve teknolojinin gelişimi ile beraber son yıllarda adını daha sık

duyduğumuz veri madenciliği eğitim konusuna da katkı sağlayabilecek önemli teknikler barındırır. Veri madenciliği veri seti içerisinde saklı bulunan paternleri keşfetme işlemidir [8]. Bir başka deyişle ham veriyi bilgiye dönüştürme veya anlamlı hale getirme işlemi veri madenciliği ile yapılır [9]. Dijital verilerin saklanmaya başlanması ile beraber veritabanları da aynı paralelde artmaktadır. Yüksek kapasiteli işlem gücünün de ucuzlaması verinin saklanmasını kolaylaştırmakta bu da bir yığın veri oluşmasına sebep olmaktadır [10]. Bu da veri madenciliğinin ne kadar gelecek vaadedici bir alan olduğu konusunda fikir vermektedir. Pazarlama, bankacılık, biyoloji, haberleşme sistemleri, endüstri, sağlık, kriminoloji, istihbarat gibi çok çeşitli dallarda uygulama alanı bulur [11,12,13]. Veri madenciliği, makine öğrenmesi, örüntü tanıma gibi kavramlar aslında bir bütünü ifade eder ve birbirleri ile çok ortak yönü vardır. Burada asıl amaç veritabanı üzerinde daha önceden gizli kalmış, kullanılabilir bilgilerin açığa çıkmasına yardımcı olmaktır.

Bu çalışma birtakım veriler kullanılarak eğitim sistemini daha kaliteli ve verimli işletmek üzere neler yapılabileceği sorusu üzerinden yola çıkarak hazırlanmıştır. Eğitim konusu tüm dünya ülkelerinin üzerinde hassasiyetle durduğu önemli bir konudur. Bir ülkenin ekonomik ve siyasi yönden daha ileriye gitmesi o ülkede yaşayan bireylerin iyi bir eğitim almasıyla direkt bağlantılıdır. Eğitim düzeni, toplum sistemi ve toplumsal ihtiyaçlar ile iç içe konulardır. Bütün ülkeler değişen modern üretim tarzlarını kapsayan bir dinamizm içerisinde bulunurken bu dinamizme adapte olacak biçimde okul ve öğretim işlerini yenilemek zorundadır [14].

Daha önce yapılan bir çalışmada 16 farklı özelliğe sahip 480 veri üzerinde çeşitli yöntemler kullanılarak öğrencilerin başarı durumlarının tahmini yapılmıştır [15]. Bu çalışmada ise aynı veri setindeki 10 özellik kullanılarak Yapay Sinir Ağları ile sınıflandırmaya gidilecektir. Daha sonra ise sonuçlarla beraber son değerlendirmeler verilecektir.

2. Problem Tanımı

Yukarıda anlatılanların paralelinde eğitim sisteminin daha iyi işlemesi ülkelerin menfaatine olduğuna göre mevcut sistemlerini iyileştirecek yeni yöntemleri keşfetmeleri ve uygulamaları oldukça kritik bir konudur. Öğrencilerin okullarında başarılı olması bu paralelde istenilen bir durumdur. Akademik

performansı arttırmak için hangi öğrenciye hangi metodu uygulamak gerektiğini bilmek kritiktir. Öğrenciye yanlış bir destek verilirse bu durum zaman ve emek kaybına yol açabilir. Bu sebeple hangi öğrencinin ne şartlar altında başarılı ya da başarısız olacağı kestirilebilirse o öğrenciye özel bir program oluşturularak yetenekleri daha iyi kullanılabilir. Bu şekilde hem boşa emek harcanmadan hem de öğrenci odaklı eğitim verilmiş olunur. Öğrencinin başarısı kendine has eğitim programı ile artmış olur.

Bu anlatılanlar doğrultusunda öğrencinin akademik başarısını öngörebilmek önemli bir konudur denilebilir ve gerçekleştiği takdirde eğitim sürecine ciddi katkılar sağlayabilir.

3. Yöntem

Öğrencinin akademik başarısının tahmininde kullanılacak veriler ve uygulanacak yöntem bu başlık altında anlatılacaktır. Çalışmada yapay sinir ağları kullanılmıştır. Yapay sinir ağları insan beyninin en önemli özelliklerinden öğrenmeyi yerine getiren bilgisayar sistemleridir [16]. Yapay sinir ağları belli sayıda yapay sinir hücresinin biraraya gelip belli bir mimari oluşturmasıyla ortaya çıkar [17]. Bu mimari çok katmanlı bir yapıda olup ilk katman giriş katmanıdır. Son katman ise çıkış katmanıdır. Arada kalanlar ise ara katman olarak adlandırılır. Sayıları birden fazla olabilir. Ortak adları gizli katmandır [18, 19]. Bir katmanın çıkış sinyali diğer katmana giriş olarak gelir. Giriş katmanında k adet, gizli katmanda h adet ve çıkış katmanında q adet nöron varsa bu tek katmanlı ileri beslemeli sinir ağı k-h-q ağı olarak bilinir [18]. Bir problemi çözerken hangi özelliklerin problemin çözümünde daha etkili olabileceğini anlamak çalışmanın başarısını olumlu etkileyecektir. Burada da seçilen önemli veriler yapay sinir ağları yöntemi ile Knime üzerinde analiz edilmiştir. Knime açık kaynak kodlu program <https://www.knime.org/> üzerinden indirilebilir. Konu ile ilgili detaylarla sırasıyla bakılacaktır.

3.1. Veriler

www.kaggle.com üzerinden edinilebilen verilerin bu çalışmada kullanılan özellikleri açıklamaları ile birlikte aşağıda verilmiştir [15].

Gender: Cinsiyet (Male, Female)

Stage ID: Eğitim Seviyeleri (LowerLevel, Middleschool, HighSchool)

Grade ID: Dereceler (G-0 – G-12 arası)

Topic: Dersler (‘English’, ‘Spanish’, ‘French’, ‘Arabic’, ‘IT’, ‘Math’, ‘Chemistry’, ‘Biology’, ‘Science’, ‘History’, ‘Quran’, ‘Geology’)

Semester: Dönem (Fall veya Spring)

Visited Resources: Öğrencinin ders içeriğini kaç kez görüntülediği (0-100 arası)

Announcements View: Öğrencinin duyuruları kaç kez kontrol ettiği, (0-100 arası)

PAS (Parent Answering Survey): Ebeveynin okul tarafından verilen anketi doldurup doldurmadığı (Evet, Hayır)

PSS (Parent School Satisfaction): Ebeveynin okuldan memnun olup olmadığı (good veya bad)

StudAbsDays (Student Absence Days): Öğrencinin kaç kez derste bulunmadığı (above-7, under-7)


Class: Öğrencinin akademik başarısı (Low-Level (L) 0-69, Middle-Level (M) 70-89, High-Level (H) 90-100)

3.2. Verilerin Uygulamaya Koyulması

Yukarıda bahsi geçen özelliklerden oluşan veri seti üzerinde analiz yapmak için Yapay Sinir Ağları kullanılmıştır. Bir veri analizi yapmadan önce yapılacak iş önce verileri hazırlamaktır. Bu uygulamadaki veri sayısı toplam 480’dir. Veriler öncelikle kategorik durumdan sayısal duruma getirilmiştir. Daha sonra bir normalizer kullanılarak belli aralıklar içerisinde tutulmuştur. Bu çalışmada kullanılan normalize etme yöntemi olarak Z-Score seçilmiştir. Bu yöntemde yeni değer, eski değerden ortalamanın çıkarılıp standart sapmaya bölünmesi ile bulunur. Verileri normalize ettikten sonra analizde kullanacağımız özellikleri belirleyebilmek için bir Column Filter kullanırız. Bundan sonra yöntemi uygulamak kalır. Tam bu noktada Yapay sinir ağlarına ait bileşenler projeye eklenir ve çalıştırılır. Çalışmanın sonunda gerekli istatistikler çıkmış olur.

4. Uygulama

Bu başlıkta uygulama ilgili detaylar adım adım anlatılacaktır. Herşeyden önce verilerin okunması için bir reader ekrana eklenir. Projede kullanacağımız veri seti bu reader yardımı ile çekilir ve istenildiğinde tekrar tekrar kullanılır. Daha sonra verileri hazırlamak üzere reader üzerine bir dizi Rule Engine eklenir. Bu Rule Engine öğeleri üzerinden tüm kategorik



özellikler sayısal özelliklere dönüştürülür (Şekil 1.).

Şekil 1. Uygulamanın birinci kısmı

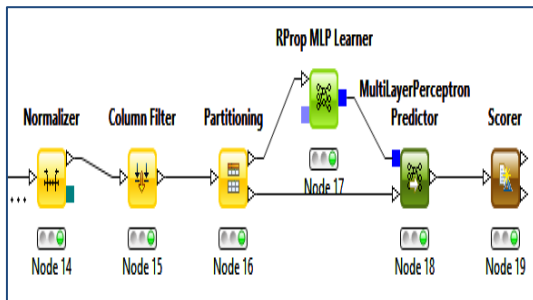
Herbir kategorik değer için bir Rule Engine kullanılır. Rule Engine kullanmadan önce ve kullandıktan sonraki birkaç özellik Şekil 2. üzerinde örnek olarak gösterilmiştir.

Row ID	Topic	Semester	Row ID	TopicNew	SemesterNew
Row0	IT	F	Row0	1	1
Row1	IT	F	Row1	1	1
Row2	IT	F	Row2	1	1
Row3	IT	F	Row3	1	1
Row4	IT	F	Row4	1	1
Row5	IT	F	Row5	1	1
Row6	Math	F	Row6	4	1
Row7	Math	F	Row7	4	1
Row8	Math	F	Row8	4	1
Row9	IT	F	Row9	1	1
Row10	Math	F	Row10	4	1
Row11	Math	F	Row11	4	1
Row12	IT	F	Row12	1	1
Row13	Math	F	Row13	4	1
Row14	Math	F	Row14	4	1
Row15	IT	F	Row15	1	1

Şekil 2. Rule Engine ekledikten sonra verilerde oluşan değişimler için bir örnek

Kategorik verilerin sayısal verilere dönüştürülmesine ihtiyaç duyulan sayı kadar Rule Engine kullandıktan sonra bu sayıların normalize edilmesi sağlanır. Bu durumda Rule Engine dizisinin hemen ardından bir Normalizer eklenir ve tüm sayısal değerler normalize edilir. Daha önceden de bahsedildiği gibi bu çalışmada normalizasyon tekniği olarak Z-Score kullanılmıştır. Analiz esnasında hangi özelliklerin analize gireceğini ayarlamak için Normalizer üst çıkışı Column Filter öğesine bağlanır. Bu öğe ile analize olumlu ya da olumsuz etkisi olduğu düşünülen özellikler eklenip çıkarılabilir. Yukarıda bahsedilen ilgili kaynaktan edinilen veri setinde 16 özellik bulunurken bu çalışmada analizde en başarılı

sonucu veren, yukarıda bahsedilen 10 tanesi kullanılmıştır. Eklenip çıkarma işlemini gerçekleştiren Column Filter ögesini Partitioning takip eder. Bu çalışmada eğitim için %70, test için %30 oranı belirlenmiştir. Partitioning ögesinde iki çıkış bulunmaktadır. Çıkışın biri öğrenme için kullanılacak verileri sağlarken diğer çıkış sistemin testi için veriler sağlar. Öğrenme verileri RProp MLP Learner ögesine bağlanır. Bu öge üzerine çift tıkladığında iterasyon sayısı, gizli katman sayısı, ve bu gizli katmanlardaki nöron sayısı gibi bilgiler ayarlanabilir. Bu çalışmada 800 iterasyon, 10 gizli katman ve gizli katman başına 10'ar nöron kullanılmıştır. RProp MLP Learner ögesinin çıkışı ile MultiLayer Perceptron Predictor ögesine bağlanır. Bu predictor ögesi, öğrendiği kuralları test verisine uygulayarak sistem güvenilirliğini test etmeye yarar. En son istatistiksel öğeleri görmek için ise MultiLayer Perceptron Predictor ögesinin çıkışına Scorer bağlanır. Bu öge üzerinden sistemin ne kadar güvenilir çalıştığı görülebilir. Analiz esnasında veriler üzerinde çalışacak algoritmik değerler (gizli katman sayısı, iterasyon sayısı vs.) veya analize katkı edebileceği özellikler değiştirilebilir. Bu analizde Column Filter yardımı ile veri setindeki özellikler eklenip çıkarılmak suretiyle sistem defalarca test edilmiş, en başarılı sonuç yukarıdaki 10 özellik üzerinde yapılan analizde alınmıştır. Rule Engine düzenlemesinden sonraki kısım Şekil 3. üzerinde verilmiştir. Bu uygulamada Node 2' den Node 13' e kadar olan tüm öğeler Rule Engine ögesidir.



Şekil 3. Uygulamanın ikinci kısmı

Bu başlık altında, Knime açık kaynak kodlu program kullanarak problem modellemesi yapılmıştır. Bundan sonraki kısımda bulgular, tartışma ve sonuç üzerine değerlendirmeler yer alacaktır.

5. Bulgular

Problem modellemesi yukarıda yapılmıştır. Eldeki veriler üzerinde Yapay Sinir Ağları algoritması çalıştırılarak alınan sonuçların güvenilirliği hakkında kullanılan ögenin Scorer olduğu bir önceki başlıkta ifade edilmişti. Scorer ögesine çift tıklanıp Dialog ekranında çıkan ilk sütun başlığına Class; ikinci sütun başlığına ise PredClass seçip ayarlar onaylanır. Daha sonra öge üzerinde sağ tıklayıp View : Confusion Matrix seçildiğinde birtakım sonuçlar elde edilir. Bu sonuçlar Şekil 4. üzerinde gösterilmiştir.

Class \ Pre...	M	L	H
M	38	7	13
L	4	42	0
H	11	0	29

Correct classified: 109 Wrong classified: 35
Accuracy: 75,694 % Error: 24,306 %

Şekil 4. Scorer ögesinden alınan sonuçlar

Yukarıdaki şekil (Şekil 4.) kısaca şu şekilde özetlenebilir:

- Test Verilerinden alınan örneklerin 58 tanesi M; 46 tanesi L; 40 tanesi ise H sınıfına aittir.
- Gerçekte M sınıfı olan 58 örneğin 38 tanesi doğru sınıflandırılırken; 7 tanesi L, 13 tanesi ise H olarak yanlış sınıflandırılmıştır.
- Gerçekte L sınıfı olan 46 örneğin, 42 tanesi doğru sınıflandırılırken, 4 tanesi M olarak yanlış sınıflandırılmıştır.
- Gerçekte H sınıfı olan 40 örneğin, 29 tanesi doğru sınıflandırılırken, 11 tanesi M olarak yanlış sınıflandırılmıştır.
- 109 örnek doğru, 35 örnek yanlış sınıflandırılmıştır. Sistemdeki genel başarı oranı yüzde 75,694'tür.

6. Tartışma ve Sonuç

Bir ülkenin gelişmişliği o ülkede yaşayan bireylerin kaliteli ve sürekli eğitim almasına bağlıdır. Sosyo-ekonomik gelişmenin ve bu konudaki itici gücün ve verimliliğin artması temelde toplumun ve işgücünün iyi eğitilmesi

ile mümkündür. Eğitim gelir artışına yol açtığı ve nüfusun niteliklerini ve hayat tarzlarını etkileyebildiği için yatırım önceliği eğitime verilmelidir [7]. Toplumların eğitim öğretim işlerini sürekli gözden geçirerek yenilikleri adapte edecek şekilde düzenlemeleri gerekmektedir [20]. Bu noktadan yola çıkarak bireylerin eğitimleri esnasında elde edecekleri başarının aslında önemli bir konuya hizmet ettiği söylenebilir.

Hangi öğrencinin hangi şartlar altında başarılı ya da başarısız olacağı öngörülebilirse daha önceden düzenlemeler yapabilmek mümkün olabilir. Böylece emek ve zaman kaybına uğramadan doğru öğrenciyeye doğru ek programlar hazırlanarak eğitim kalitesine olumlu katkılar yapılabilir.

Bu çalışmada klasik eğitim sistemi esnasında öğrencilerin bireysel başarılarını arttırmak için belli özelliklere sahip bir veri seti üzerinden çözüm aranmıştır. Çalışmada elde edilen ve Şekil 4. üzerinde gösterilen bulgular üzerinden aşağıdaki sonuçlara ulaşılabilir:

- Bulgulara bakıldığında en başarılı doğruluk oranı düşük seviyede not alan öğrencilerin tahmini üzerinedir.
- Orta ya da yüksek başarı sağlayabilecek öğrencilerin tahmin doğruluk oranı düşük başarı gösterecek öğrenci tahmin doğruluk oranı seviyesinden daha aşağıda olsa da yine de çok alakasız sonuçların çıkmadığı söylenebilir. Örneğin yüksek seviyede başarı sağlayacak bir öğrenci düşük seviye olarak ya da düşük seviyede başarı gösterecek bir öğrenci yüksek seviye olarak sınıflandırılmamıştır.
- En düşük başarı oranı orta seviyede başarılı olacak öğrencilerin tahmini üzerinde olmuştur.

Bu çalışmada esas hedef alınan şey hangi öğrencinin başarılı ya da başarısız olacağını kestirmek olduğu için orta seviyede başarılı öğrenciler üzerinden değerlendirmeye gitmek oldukça zor olacaktır. Zaten, orta seviyeli öğrenci çok doğru sınıflandırılrsa dahi pek anlamlı olmayacaktır. En anlamlı sonuç düşük başarı gösterecek öğrencilerin seviyesinde olmalıdır. Düşük başarı gösterecek öğrenciler daha önceden tespit edilebilirse bu öğrencilere kurs yönlendirmeleri, farklı eğitim materyalleri, değişik çalışma programlarının önerilmesi, daha farklı ödevler vs. sağlanabilir. Bu şekilde öğrencinin başarısı artabilir.

Yüksek başarı sağlayabilecek öğrenci zaten iyi bir pozisyondadır. Bu konuda önlem almaya çok gerek yoktur. Fakat bu öğrenciler, sınıf motivasyonunu arttırmak veya daha ileri çalışmalar yapmak açısından kullanılabilir. Bu çalışmada yüksek seviyede başarı gösterecek öğrencilerin tespiti yine de çok iyi sayılmaz. Belki bu öğrencilerden yararlanmak için daha iyi sonuçlar verecek bir sınıflandırma yapılabilir.

Sonuç olarak bu veri setinden eğitime katkı sağlayacak şekilde anlamlı bir sonuç çıkmıştır. En azından düşük seviyeli öğrencilerin tespiti oldukça iyi yapılmıştır. Bunu bilmek bile her daim iyileştirilmeye ihtiyacı olan eğitim gibi önemli bir konu için oldukça yararlı ve kullanılabilir bir bilgidir.

Kaynaklar

- [1] M. Tezcan, “Küreselleşmenin Eğitimsel Boyutu”, *Türkiye 2. Eğitim Felsefesi Kongresi*, Van Yüzüncü Yıl Üniversitesi Eğitim Fakültesi 187-195, 23-26 Ekim 1996.
- [2] S. Toulmin, “The ambiguities of globalization” *Futures* 31, 905-912, 1999.
- [3] H. B. Kaçmazoğlu (Ocak 2002). Doğu-Batı Çatışması Açısından Globalleşme. *Eğitim Araştırmaları* 6: 44-55, Ocak 2002.
- [4] R. Balay, Küreselleşme, “Bilgi Toplumu ve Eğitim”, *Ankara Üniversitesi Eğitim Bilimleri Fakültesi Dergisi*, Sayı:2, Cilt: 37, Sayfa: 61-82, 2004.
- [5] S. Ertürk, “Eğitimde Program Geliştirme”, Ankara: Yelken Tepe Yayınları, 1972.
- [6] Sönmez, V. *Program Geliştirmede Öğretmen El Kitabı*, Ankara: Anı Yayıncılık, 2001.
- [7] Ö. Çakmak, “Eğitimin Ekonomiye ve Kalkınmaya Etkisi”, *D.Ü. Ziya Gökalp Eğitim Fakültesi Dergisi*, 11, 33-41, 2008.
- [8] B. M. Thuarisingham, *Web Data Mining and Applications in Business Intelligence and Counter Terrorism*, CRC Press LLC, Boca Raton, FL, USA, 2003.
- [9] Y. Kastro, “A Defect Prediction Method For Software Versioning”, Yüksek

Lisans Tezi, Boğaziçi University,
Computer Engineering, 2006.

Educational Technology, Sayı: 4, Cilt: 3,
Makale 16, Ekim 2004.

- [10] Ç. Kurt, O. A. Erdem, “Öğrenci Başarısını Etkileyen Faktörlerin Veri madenciliği Yöntemleriyle İncelenmesi”, *Politeknik Dergisi*, Sayı: 2, Cilt: 15, 111-116, 2012.
- [11] O. İnan, “Veri Madenciliği”, Yüksek Lisans Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, 2003.
- [12] M. Albayrak, “EEG Sinyallerindeki Epileptiform Aktivitenin Veri Madenciliği Süreci ile Tespiti”, Doktora Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, 2008.
- [13] Ö. Akgöbek, F. Çakır, “Veri Madenciliğinde Bir Uzman Sistem Tasarımı”, *Akademik Bilişim 09*, 11-13 Şubat Harran Üniversitesi, Şanlıurfa, 801-806, 2009.
- [14] T. Duman, “Türkiye’de orta öğretime öğretmen yetiştirme”, Milli Eğitim Bakanlığı Yayınları, No:2322, İstanbul: Milli Eğitim Basımevi, 1991.
- [15] I. Aljarah, E. A. Amrieh & T. Hamtini, “Mining educational data to predict student’s academic performance using ensemble methods” *International Journal of Database Theory and Application*, 9(8), 119-136, 2016.
- [16] E. Öztemel, *Yapay Sinir Ağları*, Papatya Yayıncılık, 3. Basım, Nisan 2012.
- [17] D. Şengür, A. Tekin, Öğrencilerin Mezuniyet Notlarının Veri Madenciliği Metotları ile Tahmini, *Bilişim Teknolojileri Dergisi*, Sayı: 3, Cilt:6, Eylül 2013.
- [18] İ. Türkoğlu, “Yapay sinir ağları ile nesne tanıma”, F.Ü. Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Elazığ, 112s, 1996.
- [19] K. K. Çevik, E. Dandıl, ”Yapay sinir ağları için.net platformunda görsel bir eğitim yazılımının geliştirilmesi”, *Bilişim Teknolojileri Dergisi*, Cilt: 5, Sayı: 1, Ocak 2012.
- [20] Ş. Karasar, “Eğitimde Yeni İletişim Teknolojileri – İnternet ve Sanal Yüksek Eğitim”, *The Turkish Online Journal of*