

E-ÖĞRENME ORTAMINDA KULLANILAN ÖĞRENME STİLLERİNİN WEB KULLANIM MADENCİLİĞİ İLE ANALİZİ*

Nuh YAVUZALP **

Mehmet GÜROL ***

ÖZET

Bu araştırmanın amacı öğrencilerin e-öğrenme ortamlarındaki davranışlarından öğrenme stillerinin web kullanım madenciliği aracılığıyla yapay zekâ modelleri ile algılanmasıdır. Araştırma kapsamında öğrencilerin öğrenme stilleri için Kolb'un öğrenme stilleri sınıflaması ve ölçeği kullanılmıştır. Fırat Üniversitesi Eğitim Fakültesi öğrencileri ile gerçekleştirilen çalışmaya, 230 öğrenci katılmıştır. Öğrencilerin araştırma kapsamında hazırlanan web tabanlı sistemi kullanmaya başlamadan önce ve sonra öğrenme stilleri için veri toplanmıştır. Öğrencilerin e-öğrenme ortamlarını kullandıkları süre içerisinde öğrenme stillerinde değişimler meydana geldiği tespit edilmiştir. Bu durum bireysel farklılıkları ve öğrencilerin sistemlerle etkileşimleri sonucu ortaya çıkabilecek farklılıkları da dikkate alabilen sistemlere olan ihtiyacı ortaya koymaktadır.

Öğrencilerin web kullanım davranışlarından öğrenme stillerinin belirlenmesine yönelik yapılan çalışmalarda Yapay Sinir Ağları (YSA) ve Karar Ağacı modelleri uygulanmıştır. E-öğrenme ortamında öğrencilerin kullanımına sunulan 10 öğrenme etkinliğinin ziyaret süreleri ve sayıları veri madenciliği modellerinin girişlerini, öğrenme stilleri ise çıkışı oluşturmuştur. Karar Ağacı ve YSA modellerinden elde edilen tüm sonuçlar değerlendirildiğinde, YSA modelinin Karar Ağacı modeline göre daha başarılı olduğu anlaşılmıştır. YSA modeli kendi içerisindeki algoritmalar açısından değerlendirildiğinde ise Levenberg-Marquardt algoritması %91,7 başarı ile öğrencilerin öğrenme stillerini tahmin etmiştir.

Anahtar Kelimeler: E-öğrenme ortamı, Öğrenme stilleri, Yapay sinir ağları

THE ANALYSIS OF LEARNING STYLE IN E-LEARNING ENVIRONMENT VIA WEB USAGE MINING

ABSTRACT

The aim of this study is to perceive the learning styles of the students from the behaviours in e-learning environments with artificial intelligence models via web usage mining. Kolb's learning style classification and scale have been used for the learning styles of the students. 230 students participated in the study carried out by the education faculty students of Fırat University. Data have been collected for learning styles before and after students started using the web-based system that has been prepared within the scope of the research. It has been found that students experience changes in learning styles while they are using e-learning environments. This suggests the need for systems that can take into account individual differences and the differences that students may experience with their interactions with the system.

Artificial Neural Networks (ANN) and Decision Tree models have been applied in the studies to determine learning styles from students' web usage behaviours. In the e-learning environment, the duration and frequency of visits to ten learning activities offered to students make up the entries of data mining models, and learning styles make up the output of the data mining models. When all the results obtained from Decision Tree and ANN models are evaluated, it is understood that ANN model is more successful than Decision Tree model. When the ANN model has been evaluated in terms of its algorithms, the Levenberg-Marquardt algorithm predicted learning styles of students with success of 91.7%.

Keywords: E-learning environment, Learning style, Neural networks

* Bu makale Prof. Dr. Mehmet GÜROL'un danışmanlığında yürütülen, ilk yazarın doktora tezinden üretilmiştir.

** Abant İzzet Baysal Üniversitesi, Eğitim Fakültesi, BÖTE, nuhyavuzalp@gmail.com

*** Yıldız Teknik Üniversitesi, Eğitim Fakültesi, Eğitim Bilimleri Bölümü, gurolmehmet@hotmail.com

1.GİRİŞ

1960-1970’li yıllardan günümüze kadar üzerinde birçok araştırma yapılan ve farklı modeller geliştirilerek öğrenme-öğretme sürecini etkili kılmak için “Öğrenme Stili” kavramı, psikologlar ve eğitim bilimciler tarafından irdelenmektedir. Şimşek, A. (2006, s. 98) alanyazında öğrenme stilleri ile ilgili tarihsel bulguları şöyle açıklamıştır: Saptanabildiği kadarıyla bu konu ilk kez 1937 yılında Allport tarafından bilişsel biçim adı ile çalışılmış ancak yaygın çalışmalar, davranışçı psikolojinin egemen olduğu 1960-1970’li yıllarda yapılmıştır.

Özellikle 1900’lü yılların ikinci yarısından sonra baskın olmaya başlayan psikolojik ve eğitimsel anlayışlar, bireylerin birbirlerinden farklı özellikleri olduğunu ve bu özelliklerin de öğretim sürecinde dikkate alınması gerektiğini gündeme getirmeye başlamışlardır. İnsan zihnini öğrenme sürecinde dikkate alınmayan ve öğrenmeyi bir etki-tepki bağı şeklinde açıklayan davranışçı öğrenme-öğretme anlayışının etkisinden kurtulan eğitim, bilişsel anlayışın öğrenme üzerine söyledikleriyle bireysel farklılıkları dikkate almaya başlamıştır (Küçük, 2010).

Öğrenme stili konusunda yapılan araştırmalar ile öğrenme stili modelleri ortaya konulmuştur. Bunların büyük bir çoğunluğunda her bireyin öğrenebileceğini, fakat öğrenme şekillerin birbirlerinden farklı olduğu ilkesine dayanmaktadır. Bir başka ifade ile bütün öğrenenler için genel geçer bir öğrenme stili yoktur. Ancak herkesin kendi öğrenmesini destekleyecek bir öğrenme stili vardır (Dağhan & Akkoyunlu, 2011). Ayrıca öğrenme stilleri üzerine yapılan araştırmalar, öğrencilerin kendi tercih ettikleri biçimde çalıştıkları zaman daha başarılı olduklarını göstermektedir. Ancak özellikle küçük yaşlardaki öğrencilerin yeterli deneyime sahip olmamalarından kaynaklanan yanlış ve kendilerine uygun olmayan öğrenme tercihleri başarısızlığa neden olabilmektedir. Bu nedenle özellikle küçük yaşlardaki öğrencilere ders çalışma stillerini geliştirebilmeleri için yardımcı olmak gerekir (Erden & Akman, 2003, s. 233).

Öğrencilerin belirgin davranışlarını gözlemleyerek tanımlanan öğrenme stili, öğrencinin en iyi nasıl öğrendiğini ortaya koyar. Stil karakteristikleri bireyin, genetik kodlarını, kişisel gelişimlerini ve çevresel uyumlarını yansıtır. Bu karakteristikler, bireylerin öğrenme davranışlarındaki devamlı gözlemlenebilen özellikleri ile ilişkilidir (Keefe, 1985).

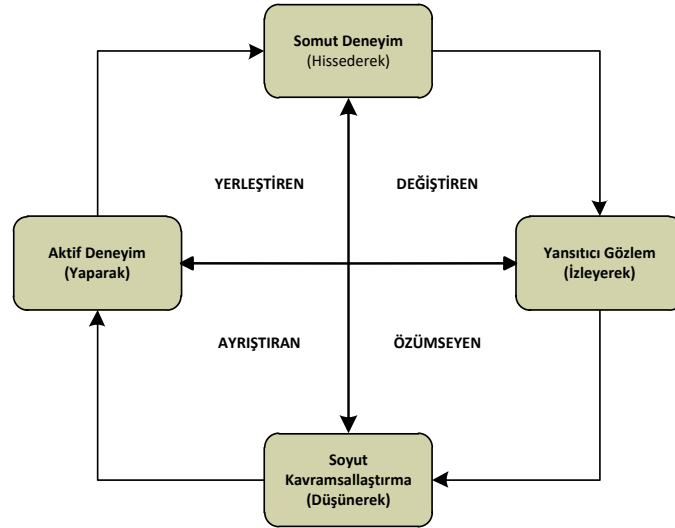
Öğrenme Stilleri ve Sınıflamaları

Öğrenme stilleri ile ilgili yapılan çeşitli tanımlamalar, öğrenme stili sınıflamalarına da yansımıştır. Öğrenme stillerinde yapılan farklı sınıflamaların temel sebebi, öğrenme stili modellerini ortaya koyan araştırmacıların öğrenme stillerinin farklı boyutlarını ele almalarından kaynaklanmaktadır. Ayrıca bu sınıflamalar kapsamında bireylerin öğrenme stillerinin belirlenmesi için kullanılan ölçeklerin farklı teorik temellere dayandığı söylenebilir. De Bello (1990), birçok modelin birbiri ile örtüştüğünü, ancak bazı öğrenme stili modellerinin bilişsel, duyuşsal ve devinimsel gibi (çok boyutlu) davranışsal özelliklerin tümüne birden dayanırken, bazılarının ise sadece bilişsel ya da psikolojik gibi tek boyutla sınırlı kaldığını ifade etmiştir. Alanyazındaki sınıflamaların bazıları özgün yaklaşımlar ile geliştirilmiş olsa da büyük çoğunluğunun önceki çalışmalar esas alınarak geliştirildiği söylenebilir.

Yaygın olarak kullanılan öğrenme stili modellerine bakacak olursak, Witkin'in geliştirdiği alan-bağımlı ve alan-bağımsız sınıflaması ile Kolb'un geliştirdiği uyarlayıcı, ayrıştırıcı, birleştirici ve özümseyici sınıflaması örnek olarak verilebilir (Desmedt & Valeke, 2004). Öğrenme stillerinin tanımlarındaki farklı değişkenlere bağlı olarak farklı modeller ortaya konmuştur. Given (1996), bu modellerin; *Duyuşsal veya kişilik özelliklerine dayalı yaklaşımlar*, *Öğrenme stilinde sosyal yaklaşımlar*, *Öğrenme stilinde bilgiyi işleme yaklaşımlar*, *Öğrenme stilinde fiziksel yaklaşımlar*, *Öğrenme stilinde çevresel ve öğretimsel yaklaşımlar* gibi kategorilerden biri ya da birkaçına girdiğini belirtmiştir. Bu araştırmada yaygın olarak kullanılan Kolb'un öğrenme stili modeli tercih edilmiştir.

Kolb'un öğrenme modeli sınıflaması:

Kolb'un öğrenme stili modeli deneyimsel öğrenme kavramına dayanmaktadır. Alanyazın incelendiğinde deneyimsel öğrenme kavramına ilk olarak Dewey, Lewin ve Piaget'in çalışmalarında rastlanmaktadır. Kolb (1984, s. 20) "deneyimsel" teriminin kullanılmasını iki önemli sebeple açıklamıştır. Bunlardan birincisi şüphesiz çalışmalarının Dewey, Lewin ve Piaget'e dayanması, ikincisi ise deneyimsel ifadesinin öğrenme sürecinin merkezinde yaşantının/deneyimlerin olmasına bağlanmaktadır.



Şekil 1: Kolb'un Öğrenme Stili Modeli

Kaynak: Using Kolb's Learning Style Inventory for E-Learning Personalization. *IADIS International Conference on Cognition and Exploratory Learning in Digital Age* (s. 121-128). Germany: CELDA 2008 Proceedings.

Yukarıdaki şekilde görüldüğü üzere Kolb'un öğrenme döngüsü yatay ve dikey boyutlara ayrılmıştır. Yatay boyut aktif deneyim'den, yansıtıcı gözleme giderken, dikey boyut somut deneyim'den, soyut kavramsallaştırmaya gitmektedir (Bechter & Esichaikul, 2008; Kolb D. A., 1984, s. 68-69). Kolb'un deneyimsel öğrenme modelinde belirttiği öğrenme stilleri yukarıda bahsedilen öğrenme biçimlerinin ikili birleşimlerinden oluşmaktadır. Bu stiller Değiştiren (somut deneyim–yansıtıcı gözlem), Özümseyen (somut kavramsallaştırma–yansıtıcı gözlem), Ayrıştırıcı (soyut kavramsallaştırma–aktif

deneyim) ve Yerleştiren (somut deneyim–aktif deneyim) olarak tanımlanmıştır. Aynı zamanda bu öğrenme stillerini oluşturan öğrenme biçimi gruplarının her birinin özelliklerini taşıdığı söylenebilir. Öğrenme stilleri ile ilgili yapılan araştırmalarda e-öğrenme ortamlarında öğrenenlerin öğrenme stillerini belirlemeye yönelik Kolb’un öğrenme stili sınıflamasının yaygın olarak kullandığı görülmektedir. Konuyla ilgili bazı araştırmalar şöyledir;

Bechter ve Esichaikul (2008)’un yaptıkları araştırmada, işletme yönetiminde yüksek lisans (MBA) yapan 180 öğrenciye Kolb’un öğrenme stili ölçeğini uygulayarak öğrenme stillerini belirlemişlerdir. Öğrencilerin e-öğrenme ortamlarında kullandıkları araçları ve öğrenme stillerinin online öğrenme ortamlarında davranışlarını nasıl etkilediğini tespit etmeye çalışmışlardır. Araştırma sonuçlarına göre, öğrencilerin e-öğrenme ortamındaki davranışları arasında öğrenme stillerine göre anlamlı farklılıklar olduğunu tespit etmişlerdir.

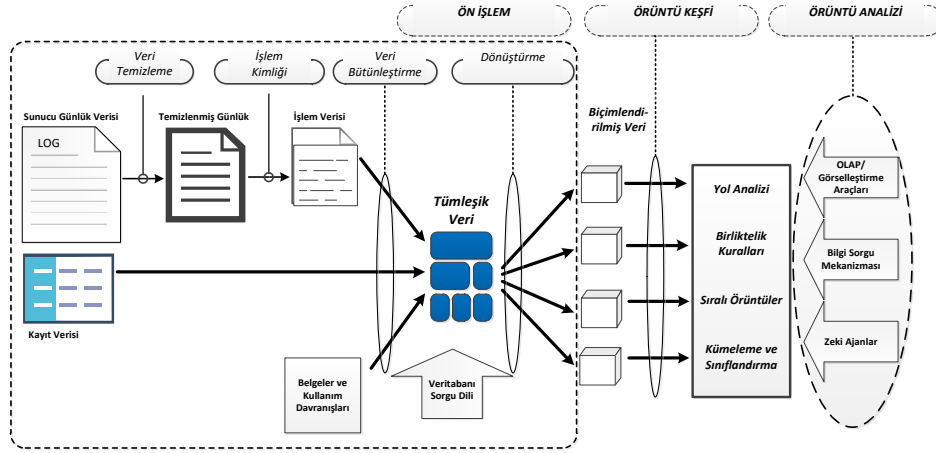
Klasnja-Milicevic, Vesin, Ivanovic ve Budimac (2011), “E-Learning personalization based on hybrid recommendation strategy and learning style identification” isimli çalışmalarında öğrencilerin öğrenme stillerine ilişkin PROTUS sistemi üzerinde web kullanım davranışlarından kurallar belirlemeye çalışmışlardır. Kontrol (n=100) ve deney (n=340) grubu üzerinde yapılan araştırmalar sonucunda, öğrencilerin ilgileri, alışkanlıkları ve öğrenme stillerine göre e-öğrenme ortamlarının adapte edilebileceğini ortaya koymuşlardır.

Web Kullanım Madenciliği

Veri tabanlarından bilgi keşfi olarak da adlandırılan veri madenciliği, bir veri kaynağından (veri tabanları, metinler, resimler, web sayfaları vb.) faydalı örüntülerin veya bilgilerin keşfedilme süreci olarak tanımlanmaktadır (Liu, 2007, s. 6). Web madenciliği, veri madenciliği teknikleri kullanılarak, www kaynakları ve servislerinden elde edilen geniş datalardan otomatik olarak önemli bilgilerin keşfedilmesi anlamına gelmektedir (Etzioni, 1996). Web madenciliği ise, kullandığı verilere göre genel olarak kendi içerisinde; web içerik madenciliği, web yapı madenciliği ve web kullanım madenciliği olmak üzere üç gruba ayrılmaktadır (Han, Kamber, & Pei, 2012, s. 597; Mobasher, 2009, s. 2085; Liu, 2007, s. 7; Pal, Talwar, & Mitra, 2002). Web kullanım madenciliği, veri madenciliği ve web madenciliği alanlarına dayanmaktadır.

Web kullanım madenciliği yöntemde web kullanıcılarının sayfalarda fare tıklamaları ile oluşturdukları kullanıcı erişim loglarından, kullanıcıların davranış analizleri yapılarak, örüntüleri keşfedilmeye çalışılır (Han, Kamber, & Pei, 2012, s. 598; Liu, 2007, s. 449). Bu süreçte bilgi keşfi için veri madenciliğinin birçok algoritması da kullanılmaktadır (Liu, 2007, s. 7). Web kullanım madenciliğinde sunucu tarafında tutulan server logları ve kullanıcı tarafında tutulan proxy logları ve kullanıcının internet gezinti geçmişi ya da çerezleri örüntü keşfi için kullanılmaktadır (Lu, Yao, & Zhong, 2003, s. 176-177).

Veri madenciliği yöntemiyle ham verilerden anlamlı bilgi elde etme sürecini, Cantu-Paz ve Kamath (2002, s. 49-50) iki temel adımda gerçekleştirdiğini, bunlardan birincisinin ham verilerden önışlem süreci ile bilgilerin elde edilmesi ve ikincisinin ise önışlenmiş verilerden anlamlı bilginin elde edilmesi ve kullanılmasını belirttişlerdir. Burada önışlem sürecinin zaman aldığı ancak anlamlı bilginin elde edilmesi için önemli olduğunu da vurgulamışlardır.



Şekil 2: Web Kullanım Madenciliğinin Genel Mimarisi

Kaynak: Daş, R., & Türkoğlu, İ. (2009). Creating meaningful data from web logs for improving the impressiveness of a website by using path analysis method. *Expert Systems with Applications*, 6(3), 6635-6644. doi:10.1016/j.eswa.2008.08.067

Yukarıdaki şekilde web kullanım madenciliğinin genel mimari yapısı verilmiştir. Şekilden de anlaşıldığı üzere, web kullanım madenciliği önemli ve yorucu bir süreci içerisine alan ön işleme, örüntü keşfi ve örüntü analizi olmak üzere üç aşamada gerçekleşmektedir (Daş ve Türkoğlu, 2009; Daş ve Türkoğlu, 2010).

Web kullanım madenciliği kullanıcıların sunucu erişim kayıtlarından örüntülerinin otomatik olarak keşfedilmesidir. Bu kayıtlar, kuruluşlar tarafından web sunucuları ve sunucu erişim kütüklerinin bir araya getirilmesi ile günlük kullanımlardan elde edilen büyük ölçekli verilerdir. Ayrıca kullanıcıların bilgilerini içeren vekil (proxy) sunucu günlükleri, CGI kodları ile toplanan araştırma verileri, kullanıcı kayıtları ve web bağlantılarını da içine almaktadır (Cooley, Mobasher, & Srivastava, 1997). Veri madenciliği ve web madenciliği yöntemiyle e-öğrenme ortamlarından anlamlı bilgiler elde etmeye yönelik çok fazla çalışma vardır. Bu bağlamda, e-öğrenme ortamlarında web madenciliği yöntemleri kullanılarak öğrenenlerin bireysel farklılıklarına ve kullanıcı profillerine yönelik yapılan araştırmalar incelenmiştir.

Markellou, Mousourouli, Spiros ve Tsakalidis (2005) "Using Semantic Web Mining Technologies for Personalized E-Learning Experiences" isimli çalışmalarında öğrencilerin e-öğrenme deneyimlerinin anlamsal web madenciliği teknolojileri ile belirlenmesi amaçlamışlardır. Araştırmada, öğrencilerin çevrimiçi ve çevrimdışı öğrenme görevleri incelenmiştir. Öğrencilerin bireysel ihtiyaçlarının ve öğrenme gereksinimlerinin anlamsal web madenciliği teknolojileri ile belirlenebileceğini ifade eden araştırmacılar, bir etki alanı ontolojisi ve kullanıcıların kişiselleştirilmiş kullanım profillerini çıkarmışlardır.

Villaverde, Godoy & Amandi (2006) "Learning Styles' Recognition in E-Learning Environments with Feed-Forward Neural Networks" isimli çalışmalarında yapay sinir ağı modellerinde backpropagation algoritmasını kullanarak e-öğrenme ortamlarında öğrenme stillerini tanımlamayı amaçlamışlardır. Felder-Silverman öğrenme stili ölçeğini

kullanarak öğrencilerin öğrenme stillerini belirlemişlerdir. Daha sonra öğrencilerin web geçmişlerinden öğrenme stillerindeki değişimleri belirlemeye çalışmışlardır.

Mota (2008) “Using learning styles and neural networks as an approach to elearning content and layout adaptation” isimli çalışmasında Kolb’un öğrenme stili sınıflamasını kullanmıştır. Yapılan çalışmada yapay sinir ağı modelleri ile öğrencilerin web sayfalarındaki sıralı gezinmelerini dikkate alınmıştır. Öğrencilere öncelikle resmi müfredat sunulmuş ve öğrencilerden alınan geri dönütler ile içerikler öğrencilerin özelliklerine göre adapte edilmiştir.

Genel olarak yapılan araştırmalar incelendiğinde, son yıllarda e-öğrenme ortamlarında öğrenme stillerinin ve stratejilerinin kullanılmasına yönelik çalışmalar yapıldığı görülmektedir. Özellikle veri madenciliği ve yapay zekâ alanının gelişmesiyle, uyarlanabilir zeki öğretim ortamları e-öğrenme çalışmalarını etkilemiştir. Yapılan benzer araştırmalar incelendiğinde, genel olarak yapay sinir ağlarının öğrenme stillerinin belirlenmesinde etkili bir model olarak kullanılması dikkat çekmektedir. Yapılan tüm araştırmalar sonucunda farklı sonuçlara ulaşıldığı görülmüş ve bu konuda yeni araştırmalara ihtiyaç olduğu anlaşılmıştır.

1.1. Araştırmanın Amacı

Araştırmanın genel amacı, e-öğrenme ortamında kullanılan öğrenme stillerini web kullanım madenciliği ile analiz etmektir.

Bu genel amaç çerçevesinde aşağıdaki hipotezler test edilmiştir.

- 1- Öğrencilerin öğrenme stilleri ile e-öğrenmede kullandıkları öğrenme araçları arasında bir ilişki vardır.
- 2- Araştırmacının test ettiği veri madenciliği modelleri öğrenenlerin öğrenme stillerini uygun algoritma ile doğru tahmin eder.

1.2. Araştırmanın Önemi

Öğrencilerin bireysel farklılıklarına göre e-öğrenme ortamlarının düzenlenmesi eğitim teknolojileri alanının önemli bir çalışma konusudur. Öğrencilere öğrenme süreci başlangıcında uygulanacak testler ile öğrenme stillerinin tespit edilerek bireysel farklılıklarına uygun öğrenme ortamlarının hazırlanması yeterli bir yaklaşım değildir. Öğrenme süreci içerisinde bu testlerin tekrar edilmesi ise, öğrencilerde olumsuz yaklaşımlara sebep olabilir. Villaverde, Godoy & Amandi (2006), e-öğrenme ortamlarının tasarlanmasında öğrencilerin öğrenme karakteristiklerinin belirlenmesinde anketlerin kullanımının zaman alıcı ve yeterli bir yaklaşım olmadığını ifade etmektedir. Bu nedenlerle, öğrencilerin öğrenme süreci içerisinde e-öğrenme ortamlarındaki davranışlarından öğrenme stillerinin yapay zekâ sistemleri yardımı ile algılanması daha doğru bir yaklaşımdır. Böylece öğretim süreci içinde bireylere sunulan etkinliklerin bireysel farklılıklarına göre düzenlenmesi mümkün olacaktır. Bu özelliklerdeki e-öğrenme ortamlarının tasarlanmasında, öğrenme stillerinin yapay zekâ modelleri ile öğrencilerin web kullanım davranışları üzerinden tespit edilmesi önemli bir boyutu oluşturmaktadır.

2. YÖNTEM

Araştırma, deneysel araştırma modellerinden “tek grup öntest-sontest desen”e göre tasarlanmıştır. Büyüköztürk, Çakmak, Akgün, Karadeniz ve Demirel (2011: 198) bu desende deneysel işlemlerin etkisinin tek bir grup üzerinde yapılan çalışmayla test edildiğini ifade etmiştir. Tek gruplu öntest-sontest desende bağımlı değişkene ilişkin ölçümlerin uygulama öncesinde öntest ve uygulama sonrasında sontest olmak üzere aynı ölçme araçları kullanılarak veriler elde edilir ve elde edilen ortalama puanlar arasındaki ilişkiye bakılır (Balcı, 2007: 212).

Araştırma için hazırlanan e-öğrenme ortamı ve veri madenciliği modelini test etmek amacıyla, önce Fırat Üniversitesi Eğitim Fakültesinde öğrenim gören Türkçe Öğretmenliği ve Matematik Öğretmenliği bölümlerinin örgün ve ikinci öğretim 2. sınıf öğrencilerinin (236 kişi) tamamına erişilmiştir. Yapılan ön çalışma ile araştırma sürecinde olası problemlerin ve veri toplama sürecinde yaşanabilecek teknik problemlerin önceden tespit edilerek gerekli önlemlerin alınması amaçlanmıştır. Ön çalışma grubuna, sadece internet erişim imkânı olan ve gönüllü olarak 106 kişi katılmıştır. Ön çalışmada öğrencilerin 4 hafta süreyle e-öğrenme ortamını kullanmaları ve sistem hakkındaki görüşlerini belirtmeleri sağlanmıştır. Aynı zamanda çalışmada kullanılacak ölçekler ve bu ölçeklerin doldurulması için geliştirilen web tabanlı sistem test edilmiştir. Ön çalışma ile elde edilen bulgular ve karşılaşılan güçlükler göz önünde bulundurularak sistemin altyapısında iyileştirmeler yapılmıştır. Ayrıca çalışmada kullanılması muhtemel veri madenciliği modelleri de test edilmiştir. Veri madenciliği işlemlerinden örüntü keşfi modellerinin sağlıklı bir şekilde uygulanabilmesi için daha çok veriye ihtiyaç duyulacağı gerçeği fark edilmiştir. Buradan çıkan sonuçlar göz önünde bulundurularak araştırmanın çalışma grubu oluşturulmuştur.

Çalışma grubu 2011-2012 eğitim öğretim yılında Fırat Üniversitesi, Eğitim Fakültesinde “Öğretim Teknolojileri ve Materyal Tasarımı” dersini Bahar döneminde alan Matematik, Türkçe, Sınıf ve Okulöncesi Öğretmenliği bölümlerinde öğrenim gören öğrencilerden oluşturulmuştur.

Çalışma grubu oluşturulurken öğrencilerin aşağıda sıralanan durumları göz önünde bulundurulmuştur.

- Temel bilgisayar kullanım becerisine sahip olma durumu
- Kişisel bilgisayara sahip olma durumu
- İhtiyaç duyulduğunda internete erişim olanağı
- Araştırmaya katılmadaki gönüllülüğü

Araştırma için seçilen çalışma grubunun oluşturulmasında göz önünde bulunduran durumlardan, temel bilgisayar kullanım becerilerine Matematik, Sınıf ve Okulöncesi Öğretmenliği bölümü öğrencileri I. sınıfta Türkçe Öğretmenliği bölümü öğrencileri ise II. sınıfta, Bilgisayar I ve II derslerini başarıyla tamamladıkları için temel bilgisayar kullanım becerisine sahip oldukları kabul edilmiştir. 2011-2012 eğitim öğretim yılında araştırma kapsamında değerlendirilen 7 (yedi) sınıftaki öğrenci sayıları ve çalışma grubunu oluşturan öğrenci sayıları Tablo 1’de verilmiştir.

Tablo 1.*Araştırmanın Çalışma Grubundaki Öğrenci Sayıları*

Bölümler	Öğrenci Sayısı	Çalışma Grubu
Matematik Öğretmenliği (Normal Öğretim)	60	34
Matematik Öğretmenliği (İkinci Öğretim)	59	31
Sınıf Öğretmenliği (Normal Öğretim)	64	30
Sınıf Öğretmenliği (İkinci Öğretim)	63	36
Türkçe Öğretmenliği (Normal Öğretim)	56	33
Türkçe Öğretmenliği (İkinci Öğretim)	57	36
Okulöncesi Öğretmenliği*	67	30
TOPLAM	426	230

* 2011-2012 eğitim öğretim yılında okulöncesi öğretmenliği bölümünün ikinci öğretimde eğitim gören öğrenci yoktur.

Araştırmanın veri toplama sürecinde öntest ve sontest olarak Kolb'un öğrenme stili envanteri kullanılmıştır. Öğrenme stilleri ile ilgili hazırlanmış ölçekler incelendiğinde, D. A. Kolb'un Deneyimsel Öğrenme Kuramı'na uygun olarak geliştirdiği öğrenme stilleri envanterinin bu alanda etkin olarak kullanıldığı ve kabul gördüğü belirlenmiştir. Kolb'un öğrenme stili envanteri (KÖSE) araştırmanın amaçlarına uygun olduğu düşünülerek kullanılmasına karar verilmiştir. KÖSE'nin son sürümü (versiyon 3), İlke Evin Gencil tarafından 2006 yılında doktora tez çalışmasında kullanılmak üzere Türkçeye uyarlama çalışması yapılmıştır (Gencil, 2007; Gencil, 2006: 109). Araştırmanın veri toplama sürecinde Kolb'un öğrenme stili envanteri (v3) öntest ve sontest olarak kullanılmıştır.

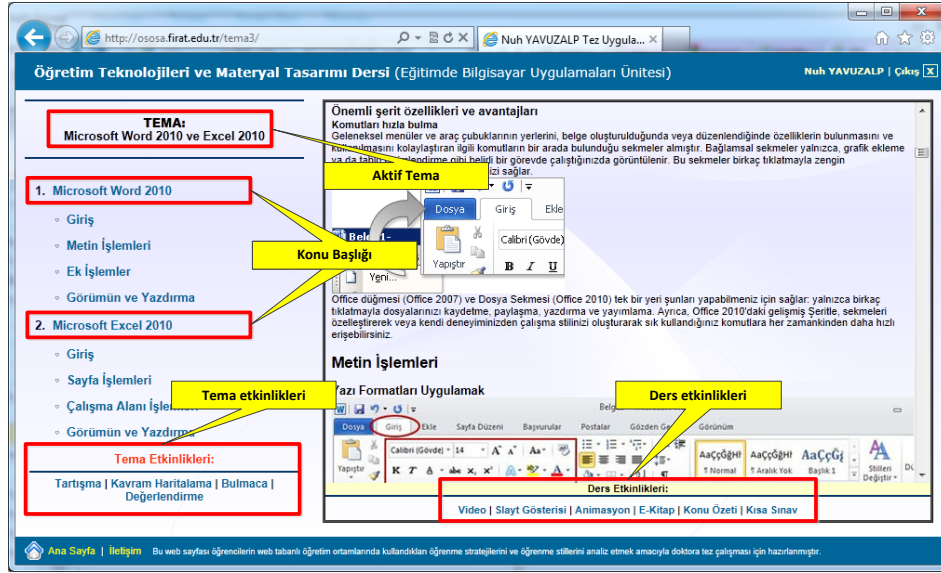
Uygulama sürecine öncelikle gerekli sistem altyapısının hazırlanmasıyla başlanılmıştır. Bu kapsamda Fırat Üniversitesi, Bilgi İşlem Daire Başkanlığına başvuruda bulunarak araştırma için kullanılmak üzere [<http://ososa.firat.edu.tr>] internet adresi tahsis edilmiştir. İnternet adresinin gerekli veri tabanı bağlantıları ve öğrencilerin web sitesi günlük (log) dosyalarının kayıt altına alınması amacıyla gerekli işlemler gerçekleştirilmiştir.

Araştırmacı tarafından tasarlanan e-öğrenme ortamında öğrencilerin her hafta bir tema ile ilgili öğrenme sürecine dâhil olmaları beklenmiştir. E-öğrenme ortamındaki "Eğitimde Bilgisayar Uygulamaları" ünitesi kapsamında sunulan dört tema aşağıdaki Tablo 2'de verilmiştir.

Tablo 2.*E-öğrenme Ortamında Sunulan Temalar ve Konu Başlıkları*

Temalar	Konu başlıkları	Alt konu başlıkları
Tema 1	Bilgisayar Nedir, Bilgisayar Destekli Eğitim ve Öğretim	Bilgisayar Nedir Bilgisayar Destekli Eğitim Bilgisayar Destekli Öğretim
Tema 2	Öğretim Yazılımları ve Türleri	Öğretim Yazılımları Öğretim Yazılım Türleri
Tema 3	Microsoft Word 2010 ve Excel 2010	Microsoft Word 2010 Microsoft Excel 2010
Tema 4	Microsoft Power Point 2010	Microsoft Power Point 2010

Temalar içerisinde kullanılacak ders içerikleri öğrenme stillerine uygun olarak ilgili literatür taraması ve uzman görüşleri doğrultusunda hazırlanmıştır. Buna göre öğrencilerin e-öğrenme ortamlarında kullanmaları için, her temada ayrı ayrı olmak üzere “Tema etkinlikleri” ve her konu başlığında ayrı ayrı olmak üzere “Ders etkinlikleri” geliştirilmiştir. Tema etkinlikleri; tartışma, kavram haritası, bulmaca, değerlendirme içermektedir. Ders etkinlikleri ise, video, slayt gösterisi, animasyon, e-kitap, konu özeti, kısa sınav içermektedir. Şekil 3’te e-öğrenme ortamının örnek ekran görüntüsü verilmiştir.

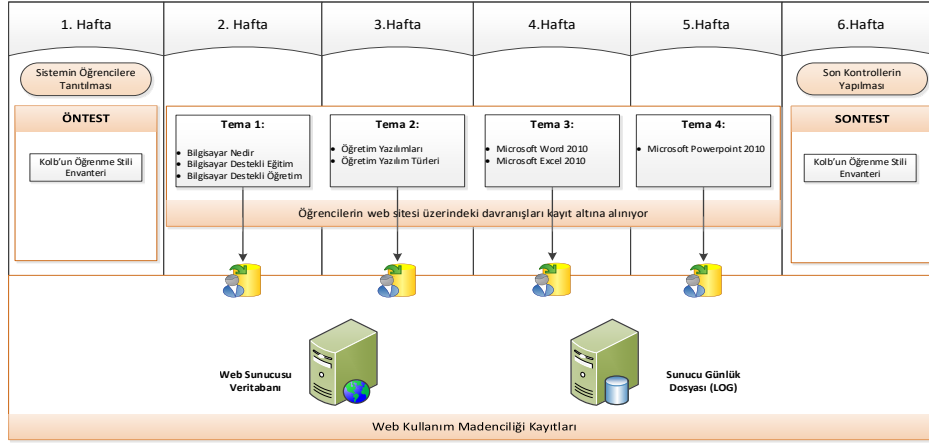


Şekil 3: Tasarlanan E-öğrenme Ortamı Ekran Görüntüsü

E-öğrenme ortamı yukarıdaki Şekil 3’te görüldüğü üzere ders etkinlikleri, tema etkinlikleri ve konu başlıkları bölümlerinden oluşmaktadır. Ders etkinlikleri, tema etkinlikleri, konu başlıkları vb. başlıklar ekranda yukarıdaki gibi kolay erişilebilecek biçimde tasarlanmıştır. Öğrenciler herhangi bir kısıtlama olmaksızın öğrenimlerini istedikleri ders/tema etkinliklerini kullanarak gerçekleştirmişlerdir.

Çalışma grubu ile yapılan uygulamada öncelikle bir uyum çalışması yürütülmüştür. Bu uyum çalışması kapsamında öğrencilere e-öğrenme ortamı tanıtılmış ve sistemi nasıl kullanacakları hakkında bilgiler verilmiştir. Ayrıca araştırmanın öntest verilerini oluşturması için ölçekleri doldurmaları istenmiştir. Daha sonra öğrenciler dört haftalık süre ile e-öğrenme ortamı üzerinden “Öğretim Teknolojileri ve Materyal Tasarımı” dersinin “eğitimde bilgisayar uygulamaları” ünitesi öğrenme etkinliklerine katılmaları istenmiştir.

Dört haftalık uygulama kapsamında öğrencilerin e-öğrenme ortamına ilk girişlerinden itibaren ortamdaki ayrılanaya kadar web sitesi üzerindeki tüm davranışları site günlükleri (log) ile kayıt altına alınmıştır. Öğrenim süresini tamamlayan öğrencilerden uygulama sonrasında sontest olarak ölçekleri tekrar doldurmaları ve sistem hakkındaki görüşlerini “öğrenci görüşleri formu”nu doldurarak iletmeleri istenmiştir.



Şekil 4: Uygulama Sürecinin Şematik Gösterimi

Yukarıdaki şekilde, uygulama sürecine ilişkin detaylar verilmiştir. 1. hafta öğrencilere e-öğrenme ortamının tanıtılması ve ön testlerin uygulaması gerçekleştirilmiştir. 2. - 5. haftalar arasında, her hafta bir tema olmak üzere toplam dört temalı öğretim programını öğrencilerin web sitesindeki tema ve ders etkinlikleri aracılığıyla öğrenmeleri istenilmiştir. Web madenciliği işlemlerinde kullanılmak üzere, öğrencilerin dört haftalık öğrenim süreci esnasında web kullanım davranışları, web sunucusu veritabanı ve sunucu günlükleri (log dosyaları) kayıt altına alınmıştır. 6. haftada ise, öğrencilere son testler uygulanarak eksik bilgi girişi olmaması için son kontroller yapılmıştır.

Araştırmada elde edilen verilerin yorumlanmasında genel olarak frekans, yüzde, t-testi ve veri madenciliği analizleri kullanılmıştır. Araştırma tek gruplu ön test-son test deneysel desende hazırlandığından, veri analizinde ilişkili grupların ortalamaları üzerinden t-testi uygulanmış ve ön test ortalamaları ile son test ortalamaları arasında anlamlı farkın olup olmadığı incelenmiştir. Tek gruplu ön test-son test deneysel desende, her deneyin iki ayrı ölçümü bulunduğundan ilişkili gruplar t-testi uygulanır (Balci, 2007: 212).

Tüm istatistiksel analizler SAS Enterprise Guide 4.3 (lisans no: 0070109432), programı ile yapılmıştır. Veri madenciliği analizleri için ise, SAS Enterprise Miner 7.1 (lisans no: 0070109432) programı ve ilgili örüntü keşfi modelleri kullanılmıştır.

```
53378.188.62.182 - - [15/Feb/2012:08:51:13 +0200] "GET /images/btn_yeni_b/2012:08:51:29 +0200] "GET /olcekler/ HTTP/1.1" 200 266088.229.42.3 - - 2012:08:53:25 +0200] "GET /images/btn_devam.jpg HTTP/1.1" 304 -78.188.62 eb/2012:08:54:29 +0200] "GET /olcekler/scripts/ga.js HTTP/1.1" 404 30478 +0200] "GET /olcekler/ HTTP/1.1" 200 266088.229.42.3 - - [15/Feb/2012:08 13.220 - - [15/Feb/2012:09:13:07 +0200] "GET /styles.css HTTP/1.1" 200 2 /2012:09:14:01 +0200] "POST /new_user.php HTTP/1.1" 200 63788.228.113.22 in.php HTTP/1.1" 302 40088.228.113.220 - - [15/Feb/2012:09:14:24 +0200] [15/Feb/2012:09:14:37 +0200] "GET /images/anasayfa.png HTTP/1.1" 304 -88 15/Feb/2012:09:15:36 +0200] "GET /styles.css HTTP/1.1" 304 -88.229.42.3 T /images/anasayfa.png HTTP/1.1" 304 -88.229.42.3 - - [15/Feb/2012:09:15 1_1.php HTTP/1.1" 200 398388.229.42.3 - - [15/Feb/2012:09:16:24 +0200] "
```

Şekil 5: Sunucu Günlük Dosyasından Bir Görünüm

Yukarıdaki Şekil 5'te web sunucusundan alınan günlük dosyasından kısa bir görünüm verilmiştir. Sunucu günlükleri genel olarak anlamsız görünen metin tabanlı dosyalardır.

Sunucu günlük dosyalardan anlamlı bilgilerin elde edilmesi için veri madenciliği uygulama sürecinin ilk basamağı olan veri temizleme işlemi yapılmıştır. Bu işlemlere ilişkin adımlar aşağıda sırayla anlatılmıştır. Sunucu bilgisayarda tutulan günlük (log) dosyası araştırma süresinin sonunda sunucu üzerinden analizlerin yapılacağı başka bir bilgisayara taşınmıştır.

Çalışma grubuna ait kişisel özellikler (cinsiyet, yaş dağılımı, öğrenim gördükleri bölümler, mezun oldukları ortaöğretim kurumu türü, kişisel bilgisayara sahip olma durumları ve internete erişim imkânları) Tablo 3'te verilmiştir.

Tablo 3:
Çalışma Grubunun Demografik Özellikleri

Demografik Özellikler		f	%
Cinsiyet	Erkek	75	32,6
	Kadın	155	67,4
Yaş	19 yaş ve altı	37	16,1
	20 yaş	82	35,7
	21 yaş	69	30
	22 yaş	27	11,7
	23 yaş ve üstü	15	6,5
Bölümler	Matematik Öğretmenliği (Normal Öğretim)	34	14,8
	Matematik Öğretmenliği (İkinci Öğretim)	31	13,5
	Sınıf Öğretmenliği (Normal Öğretim)	30	13,1
	Sınıf Öğretmenliği (İkinci Öğretim)	36	15,6
	Türkçe Öğretmenliği (Normal Öğretim)	33	14,3
	Türkçe Öğretmenliği (İkinci Öğretim)	36	15,6
	Okulöncesi Öğretmenliği	30	13,1
Ortaöğretim Kurumu	Genel Lise	169	73,5
	Anadolu Lisesi	54	23,5
	Diğer (Fen, Meslek, Açık öğretim)	7	3
Bilgisayar	Evet, bana ait bir bilgisayarım var.	80	34,8
	Evet, ortaklaşa kullandığım bir bilgisayarım var.	49	21,3
	Hayır, bir bilgisayarım yoktur.	101	43,9
İnternet	Evden ya da yurttan erişebiliyorum.	115	50
	İnternet kafelerde erişiyorum.	75	32,6
	İnternet erişim imkânım yoktur.	40	17,4
TOPLAM		230	100,0

Yukarıdaki Tablo 3'te öğrencilerin cinsiyet dağılımları incelendiğinde araştırmaya katılan öğrencilerden erkeklerin yüzde 32,6 (75 kişi) ve kadınların yüzde 67,4 (155 kişi) olduğu görülmektedir. Kadınların sayısı yaklaşık olarak erkeklerin iki katından biraz fazladır. Burada kadın sayısının yüksek olması eğitim fakültesinin öğrenci dağılımı ile doğru orantılı olmakla birlikte okul öncesi bölümünün de araştırmaya dâhil olmasının etkisi vardır.

Veri madenciliği analizlerinin yapılabilmesi için günlük (log) dosyalarında verilerin temizlenmesi işlemi gerçekleştirilmiştir. Daş (2008: 47) verilerin temizlenmesi işlemini şöyle açıklamaktadır: Erişim kütük dosyalarındaki veriler içerisinden, analiz değeri

olmayan ilişkisiz alanların arındırılması, ayıklanması ve belirli bir düzene getirilmesi önemlidir. Karmaşık ve çok zor olan bu süreç, kütüklerin içeriğine göre farklılık göstermektedir. Bu süreçte önemli olan veri kaynağından alınan verilerin işlenirken değerlerin ve bilgilerin orijinalliğini koruması, anlamlı ve doğru sonuçların üretilebilmesi için başarılı veri tablolarının oluşturulmasıdır. Bu nedenle verilerin temizlenmesi aşamasında gerekli hassasiyet gösterilmiş ve sonuç olarak 131.942 satır olan veri dosyası, temizlendikten sonra 60.686 satır olmuştur.

Bir diğer aşama olarak, web sayfasına erişen kullanıcıların öntest-sontest ölçeklerini eksiksiz olarak tamamlayanların belirlenmesi amacıyla öğrencilerin veri tabanındaki kayıtları SAS Enterprise Guide ortamına aktarılmıştır. Aktarılan ölçek verileri ilişkilendirilerek araştırma kapsamında tüm ölçekleri yanıtlayan ortak 230 kullanıcı kaydı belirlenmiş ve bu aşamadan sonra yapılan tüm analizlerde bu 230 kullanıcıya ait veriler üzerinde işlem yapılmıştır. Sunucu günlükleri ve kullanıcı oturumlarının birleştirildiği veri dosyasında son olarak 230 kullanıcıya ait kayıtların filtrelenmesi işlemi gerçekleştirilmiş ve öğrencilerin web kullanım davranışlarının bulunduğu son veri dosyası elde edilmiştir. Bu adımdan sonra 60.686 satır kayıt sunucu erişim bilgisi filtrelenmiş ve sonuç olarak web kullanıcı erişim kütükleri üzerindeki analiz işlemlerinde 42.583 kayıt veri olarak kullanılmıştır.

3. BULGULAR

Çalışma grubunun öğrenme stillerine ilişkin elde edilen bulgular aşağıda tablolar halinde verilerek yorumlanmıştır. Buna göre, aşağıdaki Tablo 4'te öğrenme stillerine göre öğrencilerin öntest, sontest dağılımları görülmektedir.

Tablo 4:
Öğrenme Stillerinin Öntest-Sontest Dağılımları

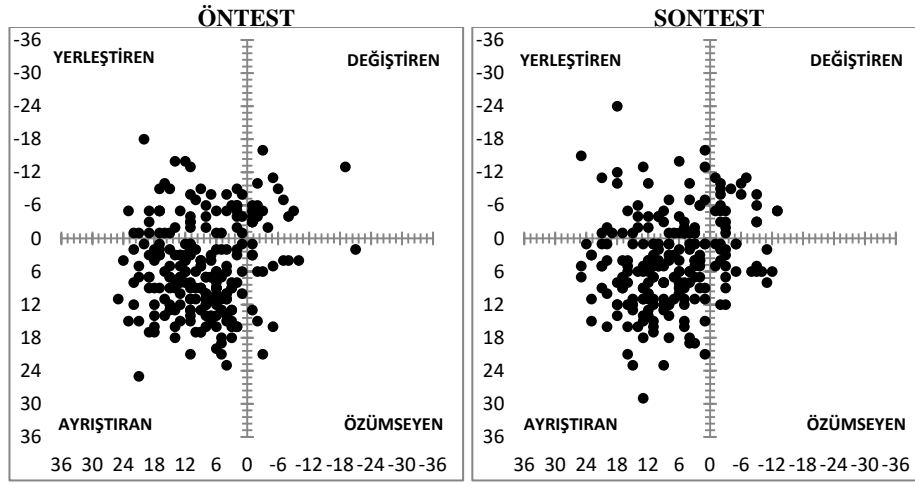
Çalışma Grubu	Öğrenme Stili	Erkek	Kadın	Toplam
ÖNTEST	Yerleştiren	16	31	47
	Değiştiren	10	9	19
	Özümseyen	6	8	14
	Ayrıştıran	43	107	150
	Toplam	75	155	230
SONTEST	Yerleştiren	13	32	45
	Değiştiren	13	9	22
	Özümseyen	11	11	22
	Ayrıştıran	38	103	141
	Toplam	75	155	230

Tablo 4'te görüldüğü üzere, öntest'teki öğrenme stillerinin dağılımında Yerleştiren öğrenme stiline olan erkekler 16 kişi, kadınlar 30 kişi olmak üzere toplam 46 kişidir. Değiştiren öğrenme stiline, erkekler 10 kişi, kadınlar 9 kişi ve toplam 19 kişidir. Özümseyen öğrenme stiline sahip, 6 erkek ve 8 kadın olmak üzere toplam 14 kişi bulunmaktadır. Ayrıştıran öğrenme stiline ise, erkekler 44 kişi ve kadınlar 107 kişi olmak üzere toplam 151 kişi bulunmaktadır. Sontest'te ise, Yerleştiren öğrenme stiline 13 erkek ve 32 kadın olmak üzere toplam 45 kişi bulunmaktadır. Değiştiren öğrenme stiline, 13 erkek ve 9 kadın olmak üzere toplam 22 kişidir. Özümseyen öğrenme stiline sahip, 12 erkek ve 11 kadın olmak üzere toplam 23 kişi bulunmaktadır. Ayrıştıran

öğrenme stilinde ise, erkekler 38 kişi ve kadınlar 102 kişi olmak üzere toplam 140 kişi bulunmaktadır.

Tablo 4 dikkate alındığında e-öğrenme ortamını kullanmaya başlamadan önce yapılan öntest ile öğrenim süreci tamamlandıktan sonra yapılan sontest arasında öğrenme stillerinin dağılımlarında farklılıklar olduğu görülmektedir. Bu durum, öğrencilerin e-öğrenme ortamlarında yaşadıkları deneyimin ve kullandıkları online etkinliklerin öğrenme stillerini etkilediğini düşündürmektedir. Buradan öğrencilerin e-öğrenme ortamında kullandıkları öğrenme araçları arasında bir ilişki olduğunu söylenebilir.

Ayrıca aşağıdaki Şekil 6'da çalışma grubundaki öğrencilerin öntest ve sontest sonuçlarına göre öğrenme stillerinin dağılımları grafik üzerinde gösterilmiştir.



Şekil 6: Çalışma Grubunun Öğrenme Stillерinin Koordinat Düzlemi Üzerindeki Öntest ve Sontest Dağılımları

Şekil 6'da görüldüğü üzere, daha önce verilen tablodaki öntest ve sontest verilerinin grafik üzerindeki dağılımları gösterilmiştir. Ayrıştırıcı öğrenme stilinde büyük bir yığılmanın olduğu söylenebilir. Bu öğrenme stilinin Türkiye'de yapılan birçok araştırmada (Demir, 2008; Uysal & Yalın, 2009) baskın öğrenme stili olarak ön plana çıktığı bilinmektedir. Bu sonucun benzer araştırmaların bulgularını destekler nitelikte olduğunu söylenebilir.

Öntest ile sontest arasındaki farklılığı incelediğimizde Yerleştiren ve Ayrıştırıcı öğrenme stillerinde azalma olurken, Değiştiren ve Özümseyen öğrenme stilinde bulunan öğrenci sayılarında artış olduğu görülmektedir. Bu durum öğrencilerin e-öğrenme çevresinde öğrenme sürecinde kullandıkları ders etkinlikleri veya tema etkinliklerinden etkilenmiş olabilecekleri düşüncesiyle açıklanabilir.

Yukarıdaki Tablo 4, Şekil 6'da görülen öğrenme stillerinin değişimlerinin anlamlılığını belirlemek üzere öğrenme stillerini oluşturan öğrenme biçimi puanları arasında yapılan bağımlı gruplar t-testi sonuçları aşağıdaki Tablo 5'te verilmiştir.

Tablo 5:

Çalışma Grubunun Öğrenme Stili Öntest ve Sontest Puanları Arasında Bağımlı Gruplar t-Testi Sonuçları

Çalışma Grubu		N	\bar{X}	SS	Sd	t	p
SK-SY	Öntest	230	8,42	7,85	229	2,17	0,031*
	Sontest	230	7,29	8,36			
AY-YG	Öntest	230	4,93	8,39	229	1,59	0,113
	Sontest	230	4,01	8,12			

* $p < 0,05$

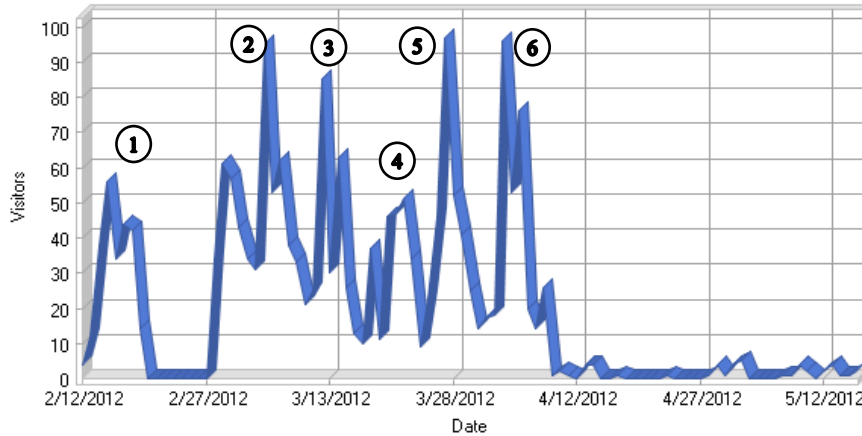
Yukarıdaki Tablo 5'ten de anlaşıldığı gibi, öğrenme stillerini oluşturan SK-SY (Soyut Kavramsallaştırma–Somut Yaşantı) ile AY-YG (Aktif Yaşantı–Yansıtıcı Gözlem) öğrenme biçimi puanlarının öntest-sontest karşılaştırması yapılmıştır. Yapılan bağımlı gruplar t-testi sonuçlarına göre, SK-SY puanlarının öntest-sontest puanları arasında anlamlı bir farklılık olduğu görülmüştür. AY-YG puanlarının öntest-sontest puanları arasında anlamlı bir farklılık oluşmasa da ortalama puanlar açısından bir değişim olduğu görülmektedir. Bu durum öğrencilerin çalışmaya başlarken öğrenme stillerine ilişkin sahip oldukları düşüncelerin süreç içerisinde öğrenme araçlarından etkilenmiş olabileceği gerçeğine bizi götürmektedir.

Veri Madenciliği Analizlerine İlişkin Bulgu ve Yorumlar

Ön işlem sürecinden geçilerek kullanılabilir veri haline getirilen sunucu günlükleri ve kullanıcı oturum bilgileri birleştirilerek veri dosyası elde edilmiştir. Bu bölümde yapılan tüm analizler ve uygulanan modeller bu veri dosyası kullanılarak gerçekleştirilmiş ve yapılan analizler sonucu elde edilen bulgular yorumlanmıştır.


Web kullanım analizleri

Aşağıdaki Şekil 7'de kullanıcıların web sayfasına günlük erişimleri grafik halinde verilmiştir.



Şekil 7: Uygulama Süresinde Öğrencilerin Web Sitesine Günlük Erişimleri

Şekil 7’de görülen 1’olu tepe noktası uygulama sürecine başlama, 2-5’no.lu tepe noktaları dört haftalık uygulama sürecini ve 6’olu tepe noktası uygulama sonrası ölçeklerin doldurulduğu zaman dilimlerini net olarak ifade etmektedir. Araştırmaya 12.02.2012 tarihinde başlanılmış ve öğrencilerin sontest ölçeklerini tamamlamaları için verilen ek süreler nedeniyle 12.05.2012 tarihine kadar uzamıştır. Bu durum grafikte de açıkça görülmektedir.



Şekil 8: Uygulama Sırasında Öğrencilerin Gün Boyunca Web Sayfasına Eriştikleri Saatler

Yukarıdaki Şekil 8’de kullanıcıların web sayfasına gün içerisinde eriştikleri saatler ortalama olarak hesaplanmış ve grafikte verilmiştir. Genel olarak en fazla yoğunluğun yaşandığı saatler 10:00-23:00 arasındadır. Web sayfasında en az yoğunluğun yaşandığı zaman dilimi ise 03:00-05:00 saatleri arasında gerçekleşmiştir.

Araştırma için hazırlanan e-öğrenme sayfasında her hafta için bir tema olmak üzere dört tema belirlenmiştir. Bu temaların konu içeriklerinin ve etkinliklerin bulunduğu web sayfalarının erişim durumu aşağıdaki Tablo 6’da verilmiştir.

Tablo 6:

Tema Sayfalarının Erişim Durumu

Web Sayfası	Erişimler	Toplam Görüntülenme Süresi	Ortalama Görüntülenme Süresi	Ziyaretler
http://ososa.firat.edu.tr/tema1/	9621	548:19:43	2:23:03	3182
http://ososa.firat.edu.tr/tema2/	5837	302:13:47	1:18:51	1828
http://ososa.firat.edu.tr/tema3/	5040	258:34:35	1:07:27	1669
http://ososa.firat.edu.tr/tema4/	4731	241:29:28	1:03:00	1417

Tablo 6’dan da görüldüğü üzere en fazla süre görüntülenen web sayfası tema 1 (548 saatten fazla) olurken en az süre görüntülenen web sayfası tema 4 (241 saatten fazla)

olmuştur. Tablo 6'dan öğrencilerin genel olarak tema sayfalarından tema 1'i yoğun olarak ziyaret ettikleri anlaşılmaktadır. Bu durum, tema 1'in konu içeriğinin üç başlıktan oluşmasına ve diğer temalardan daha fazla konu içeriğine sahip olmasına bağlanabilir. Ayrıca zaman içerisinde öğrencilerin motivasyonlarının da azalmış olması diğer bir etken olarak kabul edilebilir. Kullanıcıların ortalama sayfa görüntüleme süreleri doğrusal olarak artmış ve en fazla ziyaret edilen sayfa tema 1 (3182) olurken en az ziyaret alan sayfa tema 4 olmuştur.

Kullanıcıların öğrenme sayfalarında bulunan ders etkinliklerinde geçirdikleri toplam ve ortalama süreler ile ziyaret sayıları aşağıdaki Tablo 7'de detaylı olarak verilmiştir.

Tablo 7:*Kullanıcıların Ders Etkinliklerine Erişim Durumu*

Ders Etkinlikleri	Erişimler	Toplam	Ortalama	Ziyaretler
		Görüntülenme Süresi	Görüntülenme Süresi	
Zengin Metin	5903	354:28:41	1:32:28	2455
Video	561	78:04:59	0:20:22	305
Slayt Gösterisi	289	55:26:19	0:14:28	252
Animasyon	379	52:02:21	0:13:35	305
Konu Özeti	589	47:55:18	0:12:30	357
Kısa Sınav	406	55:47:45	0:14:33	339

Tablo 7'de görüldüğü üzere, en yüksek erişim ve ziyaret sayısı zengin metin içeriğinin bulunduğu sayfadır. Öğrencilerin bu sayfalarda geçirdikleri toplam görüntüleme süreleri ile ortalama görüntüleme süreleri incelendiğinde belirgin derecede yüksek görüntüleme süresine sahiptir. Yukarıdaki Tablo 7 incelendiğinde, öğrencilerin genel olarak zengin metin içeriğini yoğun olarak ziyaret ettikleri anlaşılmaktadır. Bunun sebebi öğrencilerin öğrenme sayfalarına ilk eriştiklerinde herhangi bir etkinliği seçene kadar zengin metin içeriğinin bulunduğu sayfayla karşılaşmaları ile açıklanabilir. Öğrencilerin ders etkinliklerini toplam görüntüleme süreleri ile ortalama görüntüleme süreleri göz önünde bulundurulduğunda genel olarak fazla kullanılan ders etkinliğinin zengin metin ve en az kullanılan etkinliğin konu özeti etkinlikleri olduğu söylenebilir.

Araştırmaya katılan öğrencilerin öğrenme sayfalarında bulunan tema etkinliklerinde geçirdikleri ortalama ve toplam süreler ile ziyaret sayıları Tablo 8'de detaylı olarak verilmiştir.

Tablo 8:*Kullanıcıların Tema Etkinliklerine Erişim Durumu*

Tema Etkinlikleri	Erişimler	Toplam	Ortalama	Ziyaretler
		Görüntülenme Süresi	Görüntülenme Süresi	
Tartışma	632	30:06:45	0:07:51	359
Kavram Haritası	337	19:30:08	0:05:05	292
Bulmaca	302	35:36:01	0:09:17	263
Değerlendirme	4530	236:35:08	1:01:43	1187

Yukarıdaki Tablo 8'de bulunan tema etkinlikleri incelendiğinde en yüksek erişim ve ziyaret sayısı değerlendirme sayfası için olmuştur. Aşağıdaki grafikte öğrencilerin tema etkinliklerine erişim durumları verilmiştir.

Öğrencilerin ünite sonlarındaki başarılarını tespit etmek amacıyla değerlendirme testini çözmeleri istenilmiş, diğer etkinlikleri kullanmaları ise isteklerine bırakılmıştır. Bu nedenle değerlendirme testini tüm öğrenciler cevapladığı için görüntüleme süreleri ve ziyaret sayıları diğer tema etkinliklerine göre belirgin bir şekilde yüksek olmuştur. Geriye kalan tema etkinliklerinde ise, erişim ve ziyaret sayısı düşük olmasına rağmen görüntüleme süresi yüksek olan bulmaca, etkinliğin özelliğinden dolayı öğrencilerin zamanını almıştır. Kavram haritası etkinliği ise, öğrencilerin bireysel farklılıkları gereği daha az tercih edilmiştir. Tartışma etkinliğinde, her haftanın konu içeriğine uygun tartışmalar farklı bir sayfada gerçekleşmiş ve tartışma sayfalarına toplam 158 mesaj gönderilmiştir.

Elde edilen veri dosyasında öğrencilerin etkinliklerin kullanımına yönelik değerler arasında büyük farklılıklar olduğu görülmüş ve veri setinin uygun hale getirilmesi için normalizasyon işlemi yapılmasına karar verilmiştir. Bu amaçla, öğrencilerin 10 etkinliğe ilişkin kullanım bilgilerinin yer aldığı veri dosyasında normalizasyon işlemleri yapılmıştır. Normalizasyon işlemi, bu konuda yapılan çalışmalarda (Villaverde, Godoy, & Amandi, 2006; Hamada, Rashad, & Darwesh, 2011) araştırmacıların tercih ettiği bir yöntem olarak karşımıza çıkmaktadır. Normalizasyon ile veri kümeleri her etkinlik için ayrı ayrı değerlendirilmiş ve -5 ile +5 aralığında dağılım yapılmıştır. Zaman verileri için en kısa süredeki kullanım -5 olarak değerlendirilirken, en uzun süreli kullanım +5 olarak değerlendirilmiştir. Ziyaret sayıları için ise, en az ziyaret eden kullanıcı -5 iken en çok ziyaret eden kullanıcı +5 olacak şekilde normalizasyon yapılmıştır. Normalizasyon işleminde aşağıdaki formül kullanılarak giriş verileri elde edilmiştir.

$$V_N = 9 \cdot \left(\frac{V_R - V_{min}}{V_{max} - V_{min}} \right) - 5 + 0,1$$

V_N : Normalize edilmiş veri
 V_R : Normalize edilecek giriş değişkeni
 V_{min} : Normalize edilecek en düşük giriş değişkeni
 V_{max} : Normalize edilecek en yüksek giriş değişkeni

Yukarıdaki formül veri madenciliği modelleri uygulanacak giriş değişkenlerinin -5 ile +5 aralığında değerlere dönüştürülmesini sağlamaktadır. Buna göre test edilen modellerde 10 giriş ($X_0 - X_9$) kullanılmıştır. Bu girişlere normalizasyon işlemi yapıldığı için her girişte -5 ile +5 aralığında değişen (0 hariç) bir puan bulunmaktadır. Veri madenciliği modellerinin çıkışı ise öğrenme stillerinden oluşmuş olup özellikleri aşağıdaki Tablo 9'da verilmiştir.

Tablo 9:
Veri Madenciliği Modelinin Çıkışı ve Öğrenme Stilinin Boyutları

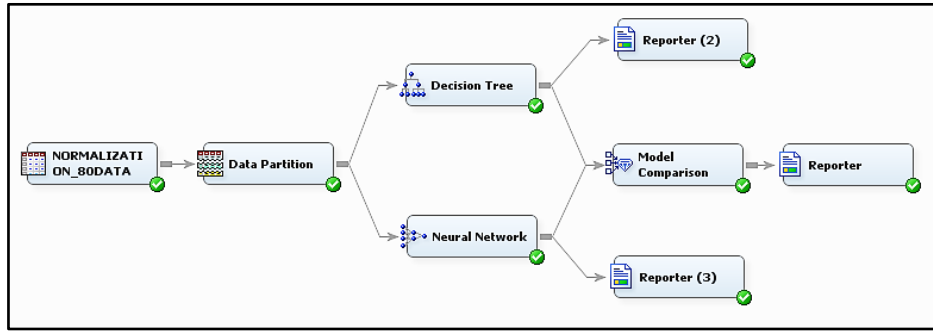
Çıkış (O ₀)	Öğrenme Stili	Boyutları
Ayrıştıran	Ayrıştıran	Yaparak – Düşünerek
Değiştiren	Değiştiren	Hissederek – İzleyerek
Özümseyen	Özümseyen	Düşünerek – İzleyerek
Yerleştiren	Yerleştiren	Yaparak – Hissederek

Tablo 9'da veri madenciliği modellerinin çıkışı verilmiştir. Buradaki çıkışta her öğrenme stilinin adı metin olarak yazılmış ve çıkış değeri olarak kabul edilmiştir. Yukarıdaki tabloda öğrenme stillerinin boyutları da sunulmuştur.

Veri madenciliği modellerinin sağlıklı çalışabilmesi için öğrenme stillerine göre öğrenci dağılımlarının eşitlenmesine karar verilmiştir. Bu amaçla her öğrenme stilinden 20'şer

öğrenci rastgele seçilerek toplam 80 öğrencilik veri seti aşağıda detayları verilen veri madenciliği modellerinde denenmiştir. Araştırma kapsamında veri setinin yapısı ve araştırmanın amaçları doğrultusunda Karar Ağacı ve Yapay Sinir Ağları modelleri uygulanmıştır. Aşağıda veri madenciliği modellerinde kullanılacak veri setinin giriş ve çıkışlarının özellikleri hakkında detaylı bilgiler verilmiştir.

Yukarıda detaylıca anlatılan tüm işlemlerden sonra YSA ve Karar Ağacı modelleri uygulanmıştır. SAS Enterprise Miner programında gerçekleştirilen analizin model görüntüsü, kullanılan node'lar ve yapılan işlemler verilmiştir. Veri kaynağında giriş ve çıkış alanlarını tanımlama işlemi yapıldıktan sonra aşağıdaki şekilde veri tablosu ilgili node'lara bağlanarak sistem çalıştırılmıştır. Burada en başarılı sonucun alındığı modelin bulunması amacıyla Karar Ağacı ve YSA modelleri ayrı ayrı denenmiştir. Uygulanan modellerin SAS Enterprise Miner programındaki diyagram görüntüsü Şekil 9'da verilmiştir.



Şekil 9: Uygulanan Veri Madenciliği Modelleri Diyagramı

Yukarıdaki Şekil 9'da görülen veri kümesi (Normalization_80Data), veri kümesine bağlı Data Partition ve Data Partition'a bağlı Karar Ağacı (Decision Tree) ve YSA (Neural Network) node'ları görülmektedir. Veri kümesinde daha önce giriş ve çıkışlar tanımlanmıştır. Data Partition node'da veri kümesinin %70'inin eğitim verisi olarak %30'unun ise test verisi olarak kullanılması için ilgili tanımlamalar yapılmıştır. Veri madenciliği modelleri ise aşağıda detayları verilen özellikleri kullanılarak ayrı ayrı test edilmiş ve en başarılı model bulunmaya çalışılmıştır. Modellerin karşılaştırmasının yapılabilmesi için ilgili node (Model Comparison) ve tüm sonuçların raporlanması amacıyla Reporter node'ları eklenmiştir.

Modelin çıkışını oluşturan öğrenme stillerinin eğitim ve test verisi olarak ayrıldığında dağılımları aşağıdaki gibi olmuştur.

Tablo 10:

Veri Madenciliği Modelleri Uygulanacak Çıkış Değişkeninin Özellikleri

Modelin Çıkışı	Veri Kümesi (%100)	Eğitim (%70)	Test (%30)
Yerleştiren	20	14	6
Değiştiren	20	14	6
Özümseyen	20	14	6
Ayrıştıran	20	14	6
TOPLAM	80	56	24

Yukarıdaki Tablo 10'da görüldüğü üzere, veri madenciliği modelleri uygulanan veri kümesinin çıkışına göre %70'i eğitim verisi olarak %30'u ise test verisi olarak kullanılmış ve öğrenme stillerine göre dağılımları eşittir.

Kara Ağacı Modelinin Uygulanması:

Karar Ağacı modelinin karar diyagramını oluştururken kullandığı giriş değişkenlerinin önem derecesi 1 – 0,66 arasında değişmektedir. Karar diyagramında video, animasyon, özet ve bulmaca olmak üzere dört giriş kullanılmıştır. Diğer girişlerin ise önem derecesi (sıfıra yakın) çok düşüktür. Karar Ağacı modelinin eğitim verilerini öğrenme başarısı değerlendirildiğinde ayırıştırıcı ve değiştiren öğrenme stillerini %100 başarı ile öğrenen model, özümseyen ve yerleştiren öğrenme stillerini %50 başarı ile öğrenmiştir. Karar Ağacı modeli, uygulamasından elde edilen sonuçlara göre, eğitim verilerinin %25'i, test verilerinin ise %41,8'i yanlış sınıflandırılmıştır. Bu sonuçlar karar ağacı modelinin %58,2 başarı ile öğrenme stillerini doğru tahmin edebildiğini göstermektedir.

YSA Modelinin Uygulanması:

YSA modelinde kullanılacak algoritma için özel bir tercih belirtilmemiş SAS Enterprise Miner programının kullanabildiği tüm algoritmalar sırayla denenmiştir. Eğitim verilerini değerlendirilmesinde modelin özellikleri tanımlanmıştır. Buna göre deneme yanılma yöntemi ile en uygun gizli katman sayısı bulunmaya çalışılmış ve sonuç olarak gizli katman sayısı 13 olarak belirlenmiştir. Ayrıca en fazla tekrarlamaya (max iterations) sayısı olarak da 50 belirlenmiştir.

YSA modeli öğrenme stillerini %100 başarı ile öğrenmiştir. Bu durum, test verilerinin tahmin edilme başarısını doğrudan etkileyecek bir sonuçtur. Elde edilen sonuçlarına göre sistem, YSA modelinde kullanılan tüm algoritmalarda eğitim verisi %100 başarı ile öğrenilmiştir. Ancak Test verilerinin sınıflamasında algoritmalara göre farklılıklar olduğu görülmüştür. YSA modelinde denen algoritmalar ve başarı sonuçları aşağıdaki Tablo 11'de verilmiştir.

Tablo 11:

YSA Modelinde Kullanılan Algoritmaların Başarı Durumu

Kullanılan Algoritma	Tekrarlamaya (Iteration)	Hatalı Sınıflama Oranı	Hatalı Sınıflanan Öğrenci Sayısı	Başarı Yüzdesi
Trust Region	10	0,292	7	70,8
Levenberg-Marquardt	4	0,083	2	91,7
Dual Quasi-Newton	8	0,250	6	75
Conjugate Gradient	10	0,250	6	75
Double Dogleg	10	0,250	6	75
Backpropagation Method	50*	0,417	10	58,3
RPROP Method	46	0,292	7	70,8
QPROP Method	24	0,250	6	75

* En fazla tekrarlamaya (iteration) sayısına ulaşıldığı için eğitim verisinin öğrenmesi %58,9'da kalmıştır.

Yukarıdaki Tablo 11'de YSA modelinde kullanılan öğrenme algoritmaları ve başarı oranları verilmiştir. Tablodan anlaşıldığı üzere Levenberg-Marquardt algoritması 24 test

verisinden 2'sini yanlış sınıflamış ve %91,7 başarıyla öğrenme stillerini tahmin edebilmiştir. Aşağıdaki Tablo 12'de elde edilen sonuçlara göre, YSA modelinin özellikleri verilmiştir.

Tablo 12:*YSA Modelinden Özellikleri*

İstatistik Bilgiler	Eğitim	Test
Örnek (öğrenci) sayısı	56	24
Hatalı sınıflama oranı	0	0,083
Yanlış yapılan sınıflama sayısı	0	2
Kullanılan YSA algoritması	Levenberg-Marquardt	
En fazla tekrarlama sayısı (Max. Iteration)	50	
Kullanılan gizli katman sayısı (Hidden Layer)	13	

Yukarıdaki Tablo 12'de YSA modelinden elde edilen istatistik sonuçlar verilmiştir. Buna göre, her öğrenme stilinden 20'şer öğrenci olmak üzere toplam 80 öğrencinin bulunduğu veri setinin %70 eğitim verisi ve %30'u test verisi olarak kullanılmıştır. Tabloda görüldüğü üzere eğitim verisi olarak 56 öğrenci, test verisi olarak 24 öğrenci sistem tarafından rastgele seçilmiştir. Yapılan yapay zekâ eğitimi sonucunda sistem %100 başarı ile öğrenmesini tamamlamış, eğitim verilerindeki hatalı sınıflama oranı 0 (sıfır) olmuştur. Test edilen 24 öğrenciden 2'sini hatalı olarak sınıflayan YSA modeli, %91,7 başarıya ulaşmıştır.

Sonuç olarak, öğrenme stillerini tahmin etmesi için geliştirilen YSA modeli %91,7 başarı ile öğrenme stilini doğru tahmin etmiştir. Bu durumda "araştırmacının test ettiği veri madenciliği modelleri öğrenenlerin öğrenme stillerini uygun algoritma ile doğru tahmin eder" hipotezi %91,7 başarıyla kabul edilmiştir.

4.TARTIŞMA ve SONUÇ

Genel olarak öntest ve sontest sonuçlarına göre öğrencilerin büyük bir çoğunluğunun ayrıştırıcı öğrenme stiline sahip olduğu görülmektedir. Bu durum diğer araştırmalarla (Demir, 2008; Uysal & Yalın, 2009) karşılaştırıldığında benzer bir sonuç olduğu anlaşılmaktadır. Öntest ile sontest arasındaki farklılığı incelediğimizde, yerleştiren ve ayrıştırıcı öğrenme stillerinde azalma olurken; değiştiren ve özümseyen öğrenme stiline bulunan öğrenci sayılarında artış olduğu görülmektedir. Bu sonuç öğrencilerin e-öğrenme ortamlarında yaşadıkları deneyimin ve kullandıkları online etkinliklerin öğrenme stillerini etkilediğini düşündürmektedir. Öğrencilerin öntest sonuçları ile sontest sonuçları arasında, aynı envanterin kullanılmış olmasına rağmen farklılıkların olması önemlidir. Çünkü bu durum web tabanlı öğrenme ortamlarının öğrencilerin bireysel farklılıklarına göre uyarlanması amacıyla geliştirilen sistemlerin uygulama süreci içerisinde yetersiz kalabileceğini göstermektedir. Çünkü öğrencilerin öğrenme stillerine göre tasarlanacak bir sistemin kullanıcı modeli oluşturulurken, öğrencilere uygulanacak öğrenme stili envanterinden toplanan veriler, bu araştırmadan elde edilen bulgulara göre süreç içerisinde çeşitli nedenlerle değişime uğrayabilmektedir. Palh (2006, s. 53) web madenciliği yöntemleri ile öğrenme stilleri ve stratejilerinin zaman içindeki değişimlerinin analiz edilebileceğini ifade etmektedir. Böyle bir durum yaşandığında öğrencinin bireysel farklılıklarına göre tasarlanacak sistemlerin kullanıcıların değişen ihtiyaçlarına cevap vermesi mümkün olmayacaktır. Bu nedenle süreç içerisinde öğrencilerin site üzerindeki davranışlarını izleyen ve yaşanabilecek değişiklikleri tespit

edebilen sistemlerin tasarlanması bu araştırmanın sonuçlarına göre daha büyük bir önem kazanmaktadır.

Alanyazında web tabanlı sistemlerde öğrenme aktiviteleri ile öğrenme stilleri arasında bir ilişki olduğu, web kullanım madenciliği tekniklerinin bu ilişkilerin belirlenmesine yardımcı olabileceği ifade edilmektedir (Bousbia, Rebaï, Labat, & Balla, 2010; Palh, 2006, s. 53-54; Rajper, Shaikh, Shaikh, & Mallah, 2016). Bu bağlamda araştırma kapsamında öğrencilerin web kullanım davranışları analiz edilmiş ve analizler sonucunda elde edilen veri kümesi, öğrencilerin öğrenme stillerini belirlemek amacıyla geliştirilen yapay zekâ modeline uygulanmıştır. Web sayfasında öğrencilerin kullanımına sunulan öğrenme etkinlikleri (tartışma, bulmaca, kavram haritası, değerlendirme, video, slayt gösterisi, animasyon, kısa sınav, özet, zengin metin) yapay zekâ modelinin girişlerini oluşturmuştur.

Öğrencilerin web sayfasındaki 10 etkinliğe ilişkin kullanım bilgilerinin yer aldığı veri dosyasında, veri madenciliği açısından anlamlılığı yükseltmek amacıyla normalizasyon işlemi yapılmıştır. Normalizasyon, işlemi bu konuda yapılan benzer çalışmalarda (Villaverde, Godoy, & Amandi, 2006; Hamada, Rashad, & Darwesh, 2011) araştırmacıların tercih ettiği bir yöntem olarak karşımıza çıkmaktadır. Normalizasyon ile veri kümeleri her etkinlik için ayrı ayrı değerlendirilmiş ve -5 ile +5 aralığında dağılım yapılmıştır. Zaman verileri için en kısa süredeki kullanım -5 olarak değerlendirilirken, en uzun süreli kullanım +5 olarak değerlendirilmiştir. Ziyaret sayıları için ise, en az ziyaret eden kullanıcı -5 iken, en çok ziyaret eden kullanıcı +5 olacak şekilde normalizasyon yapılmıştır. Veri madenciliği modelinin girişlerine normalizasyon işlemi yapıldığı için her girişte -5 ile +5 aralığında değişen (0 hariç) bir puan bulunmaktadır. Veri madenciliği modelinin çıkışı ise öğrenme stillerinden oluşmaktadır.

Araştırmaya katılan 230 öğrencinin öğrenme stili dağılımlarının orantısız olduğu görülmüş, öğrencilerin stillere göre dağılımlarının eşitlenmesi amacıyla her öğrenme stilinden 20'şer öğrenci rastgele seçilmiş, toplam 80 öğrencilik veri seti, veri madenciliği modelinde denenmiştir.

Veri kümesinin giriş ve çıkışları YSA modelinde tanımlanmış, Data Partition node'da veri kümesinin %70'inin eğitim verisi, %30'unun ise test verisi olarak kullanılması için gerekli tanımlamalar yapılmıştır. YSA modelinin uygulamasında eğitim verisi olarak 56 öğrenci, test verisi olarak 24 öğrenci sistem tarafından rastgele seçilmiştir. SAS Enterprise Miner programında YSA modeli için kullanılacak tüm algoritmalar sırayla test edilmiş ve en başarılı sonuca ulaşmaya çalışılmıştır. Yapılan denemeler sırasında 13 gizli katman kullanılmış ve en fazla tekrarlama sayısı 50 olarak belirlenmiştir. Tüm algoritmalar denedikten sonra en başarılı sonuç, Levenberg-Marquardt algoritmasından elde edilmiştir. Bu algoritma ile yapılan yapay zekâ eğitimi sonucunda sistem %100 başarı ile öğrenmesini tamamlamıştır. Test verilerinde ise 24 öğrenciden 2'sini hatalı olarak sınıflayan YSA modeli, %91,7 başarıya ulaşmıştır.

Karar Ağacı ve YSA modellerinden elde edilen tüm sonuçlar değerlendirildiğinde, YSA modelinin Karar Ağacı modeline göre daha başarılı olduğu anlaşılmıştır. YSA modeli kendi içerisindeki algoritmalar açısından değerlendirildiğinde ise Levenberg-Marquardt algoritması %91,7 başarıyla öğrencilerin öğrenme stillerini doğru tahmin etmiştir.

Araştırma kapsamında yapılan tüm analizler ve elde edilen veri madenciliği modeli ile öğrencilerin web kullanım davranışlarından öğrenme stillerinin belirlenmesinin mümkün

olduğu görülmüştür. Alanyazında web kullanım madenciliği teknikleri ile öğrenme stillerinin belirlenmesine yönelik birçok çalışma yapıldığı ve bu çalışmalarda toplanan öğrenci verileri ve farklı e-öğrenme çevrelerine göre çeşitli tekniklerin ve algoritmaların daha başarılı sonuçlar verdiği anlaşılmaktadır (Bousbia, Rebaï, Labat, & Balla, 2010; Liyanage, Gunawardena, & Hirakawa, 2016; Rajper, Shaikh, Shaikh, & Mallah, 2016; Chen & Liu, 2011; Jovanovic, Vukicevic, Milovanovic, & Minovic, 2012). Öğrenme stilleri açısından ulaşılan bu sonuçların öğrencilerin bireysel farklılıklarına göre uyarlanabilir e-öğrenme ortamlarının tasarlanmasına büyük katkı sağlayacağı düşünülmektedir. Ayrıca bazı araştırmalar sonucunda web tabanlı öğrenme ortamlarını kullanan öğrencilerin öğrenme stillerini otomatik olarak tespit eden web tabanlı araçlar geliştirmeye yönelik çalışmalar yapılmıştır (Sweta & Lal, 2015; Ba-Omar, Petrounias, & Anwar, 2007; Darwesh, Rashad, & Hamada, 2011).

Öneriler

Araştırma sonucunda ulaşılan bilgiler ışığında, öğrenme stillerinin e-öğrenme ortamlarında öğrencilerin bireysel farklılıklarını dikkate alan sistemlerin geliştirilmesine fayda sağlayacak aşağıdaki öneriler geliştirilmiştir.

- Web tabanlı ortamların tasarlanmasında öğrenme süreci öncesinde yapılacak testlerin bireysel farklılıkları dikkate almak için yeterli olmayacağı göz önünde bulundurulmalıdır.
- Uyarlanabilir e-öğrenme ortamlarının altyapısında veri madenciliği modelleri kullanılabilir.
- Öğrencilerin web kullanım davranışlarından öğrenme stillerinin tahmin edilebildiği sistemler benzer modellerle denenebilir.
- Bireysel farklılıklar veri madenciliği yöntemleri ile tespit edilerek adapte edilebilen e-öğrenme ortamları hazırlanabilir.
- Farklı öğrenme stilleri ölçeklerinin kullanıldığı yeni araştırmalar yapılabilir.

KAYNAKÇA

- Balcı, A. (2007). *Sosyal Bilimlerde Araştırma* (6 b.). Ankara: Pegem A Yayıncılık.
- Ba-Omar, H., Petrounias, I. and Anwar, F. (2007). A framework for using web usage mining to personalise e-learning. *Advanced Learning Technologies, 2007. ICALT 2007. Seventh IEEE International Conference* (s. 937-938). IEEE.
- Bechter, C. and Esichaikul, V. (2008). Using Kolb's Learning Style Inventory for E-Learning Personalization. *IADIS International Conference on Cognition and Exploratory Learning in Digital Age* (s. 121-128). Germany: CELDA 2008 Proceedings.
- Bousbia, N., Rebaï, I., Labat, J.-M. and Balla, A. (2010). Analysing the relationship between learning styles and navigation behaviour in web-based educational system. *Knowledge Management & E-Learning: An International Journal*, 2(4), 400-421.
- Büyüköztürk, Ş., Çakmak, E. K., Akgün, Ö. E., Karadeniz, Ş. and Demirel, F. (2011). *Bilimsel Araştırma Yöntemleri* (10. b.). Ankara: Pegem Akademi.
- Cantu-Paz, E. and Kamath, C. (2002). On the Use of Evolutionary Algorithms in Data Mining. H. A. Abbass, R. A. Sarker and C. S. Newton içinde, *Data Mining: A Heuristic Approach* (s. 48-71). London: Group Idea Publishing.
- Chen, S. Y. and Liu, X. (2011). Mining students' learning patterns and performance in Web-based instruction: a cognitive style approach. *Interactive Learning Environments*, 19(2), 179-192. doi:10.1080/10494820802667256
- Cooley, R., Mobasher, B. and Srivastava, J. (1997). Web Mining: Information and Pattern Discovery on the World Wide Web. *Proceedings of the 9th IEEE International Conference on Tools with Artificial Intelligence (ICTAI'97)*, (s. 558-567). Newport Beach, CA.
- Dağhan, G. ve Akkoyunlu, B. (2011). Maggie Mcvay Lynch Öğrenme Stili Envanterinin Türkçe'ye Uyarlama Çalışması. *Hacettepe Eğitim Fakültesi Dergisi*(40), 117-126.
- Darwesh, M., Rashad, M. .. and Hamada, A. K. (2011). From Learning Style of Webpage Content to Learner's Learning Style. *International Journal of Computer Science & Information Technology (IJCSIT)*, 3(6), 48-59.
- Daş, R. (2008). *Web Kullanıcı Erişim Kütüklerinden Bilgi Çıkarımı*. Fen Bilimleri Enstitüsü, Yayınlanmamış Doktora Tezi, Elazığ: Fırat Üniversitesi.
- Daş, R. ve Türkoğlu, İ. (2009). Creating meaningful data from web logs for improving the impressiveness of a website by using path analysis method. *Expert Systems with Applications*, 6(3), 6635-6644. doi:10.1016/j.eswa.2008.08.067
- Daş, R. ve Türkoğlu, İ. (2010). Web tabanlı öğretim materyallerinin web kullanım madenciliği ile analiz edilmesi, *Fırat Üniversitesi Mühendislik Bilimleri Dergisi* , 22(1), 111-122.
- De Bello, T. C. (1990). Comparison of Eleven Major Learning Styles Models: Variables, Appropriate Populations, Validity of Instrumentation, and Research behind Them. *Journal of Reading, Writing, and Learning Disabilities International*, 6(3), 203-222. doi:10.1080/0748763900060302
- Demir, T. (2008). Türkçe Eğitimi Bölümü Öğrencilerinin Öğrenme Stilleri ve Bunların Çeşitli Değişkenlerle İlişkisi. *Uluslararası Sosyal Araştırmalar Dergisi*, 1(4), 129-148.

- Desmedt, E. and Valcke, M. (2004). Mapping the Learning Styles "Jungle": An overview of the literature based on citation analysis. *Educational Psychology*, 24(4), 445-464.
- Erden, M. ve Akman, Y. (2003). *Gelişim ve Öğrenme* (12. Baskı b.). Ankara: Arkadaş Yayınevi.
- Etzioni, O. (1996). The World-Wide Web: quagmire or gold mine? *Communications of the ACM*, 39(11), 65-68.
- Gencel, İ. E. (2006). *Öğrenme Stilleri, Deneysimsel Öğrenme Kuramına Dayalı Eğitim, Tutum ve Sosyal Bilgiler Program Hedeflerine Erişi Düzeyi*. Eğitim Bilimleri Enstitüsü, Yayınlanmamış Doktora Tezi, İzmir: Dokuz Eylül Üniversitesi.
- Gencel, İ. E. (2007). Kolb'un Deneysimsel Öğrenme Kuramına Dayalı Öğrenme Stilleri Envanteri-III'ü Türkçeye Uyarlama Çalışması. *Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(2), 120-139.
- Given, B. K. (1996). Learning Styles: A Synthesized Model. *Journal of Accelerated Learning and Teaching*, 21(1-2), 11-44.
- Hamada, A. K., Rashad, M. Z. and Darwesh, M. G. (2011). Behavior Analysis in a Learning Environment to Identify the Suitable Learning Style. *International Journal of Computer Science & Information Technology*, 3(2), 48-59.
- Han, J., Kamber, M. and Pei, J. (2012). *Data Mining Concepts and Techniques* (3th b.). San Francisco: Morgan Kaufmann Publishers.
- Jovanovic, M., Vukicevic, M., Milovanovic, M. and Minovic, M. (2012). Using data mining on student behavior and cognitive style data for improving e-learning systems: a case study. *International Journal of Computational Intelligence Systems*, 5(3), 597-610. doi:10.1080/18756891.2012.696923
- Keefe, J. W. (1985). Assessment of Learning Style Variables: The NASSP Task Force Model. *Theory into Practice*, 24(2), 138-144.
- Klasnja-Milicevic, A., Vesin, B., Ivanovic, M. and Budimac, Z. (2011). E-Learning personalization based on hybrid recommendation strategy and learning style identification. *Computers & Education*(56), 885-899.
- Kolb, D. A. (1984). *Experiential Learning: Experience as the Source of Learning and Development*. Englewood Cliffs, New Jersey: Prentice Hall.
- Küçük, M. (2010). *Çevrimiçi Öğrenenlerin Öğrenme Biçimi, Öğrenme Stratejileri ve Eşzamanlı Tartışmalara Katılımları Arasındaki İlişki*. Sosyal Bilimler Enstitüsü, Yayınlanmamış Doktora Tezi, Eskişehir: Anadolu Üniversitesi.
- Liu, B. (2007). *Web Data Mining*. New York: Springer.
- Liyanage, M. P., Gunawardena, K. L. and Hirakawa, M. (2016). Detecting Learning Styles in Learning Management Systems Using Data Mining. *Journal of Information Processing*, 24(4), 740-749.
- Lu, Z., Yao, Y. and Zhong, N. (2003). Web Log Mining. N. Zhong, J. Liu and Y. Yao içinde, *Web Intelligence* (s. 173-196). Berlin: Springer.
- Mobasher, B. (2009). Web Mining Overview. J. Wang içinde, *Encyclopedia of Data Warehousing and Mining* (2nd b., s. 2085-2089). New York: Information Science Reference.
- Mota, J. (2008). Using learning styles and neural networks as an approach to elearning content and layout adaptation. *Doctoral Symposium on Informatics Engineering (DSIE'08)*. Porto, Portugal: University of Porto.

- Pal, S. K., Talwar, V. and Mitra, P. (2002). Web mining in soft computing framework: relevance, state of the art and future directions. *IEEE Transactions on Neural Networks*, 13(5), 1163-1177. doi:10.1109/TNN.2002.1031947
- Palh, C. (2006). Data mining for the analysis of content interaction in web-based learning and training systems. C. Romero and S. Ventura içinde, *Data Mining in E-Learning* (s. 41-56). Southampton, Boston: WIT Press.
- Rajper, S., Shaikh, N. A., Shaikh, Z. A. and Mallah, G. A. (2016). Automatic detection of learning styles on learning management systems using data mining technique. *Indian Journal of Science and Technology*, 9(15).
- Sweta, S. and Lal, K. (2015). Web Usages Mining in Automatic Detection of Learning Style in Personalized eLearning System. *Proceedings of the Fifth International Conference on Fuzzy and Neuro Computing* (s. 353-363). Cham: Springer.
- Şimşek, A. (2006). Öğrenme Biçimi. Y. Kuzgun and D. Deryakulu içinde, *Eğitimde Bireysel Farklılıklar* (2. b., s. 97-138). Ankara: Nobel Yayın Dağıtım.
- Uysal, M. P. ve Yalın, H. İ. (2009). Bilgi Nesnesi Tabanlı ve Öğrenme Stillere Uyarlanabilen Alıştırma Yazılımının Akademik Başarıya Etkisi. 3. *Uluslararası Bilgisayar ve Öğretim Teknolojileri Sempozyumu (ICITS 2009)*. Trabzon: Karadeniz Teknik Üniversitesi.
- Villaverde, J. E., Godoy, D. and Amandi, A. (2006). Learning Styles' Recognition in E-Learning Environments with Feed-Forward Neural Networks. *Journal of Computer Assisted Learning*, 22(3), 197-206.

EXTENDED ABSTRACT

1. Introduction

The learning style, which is defined by observing the student's specific behaviours, reveals how the student learns best. Style characteristics reflect the individual's genetic codes, personal development, and environmental harmony. These characteristics are related to the continuously observable characteristics of individual's learning behaviours (Keefe, 1985).

Data mining, also called the discovery of information from databases, is defined as the process of discovering useful information or patterns from a data source (databases, texts, images, web pages, etc.) (Liu, 2007, s. 6). Web mining means to discover automatically the important information from a wide range of data from www sources and services using data mining techniques (Etzioni, 1996). According to the information used, web mining is divided into three groups; web content mining, web structure mining and web usage mining (Han, Kamber, & Pei, 2012, s. 597; Mobasher, 2009, s. 2085; Liu, 2007, s. 7; Pal, Talwar, & Mitra, 2002). Web use mining is based on data mining and web mining.

According to the individual differences, the arrangement of e-learning environments of the students is an important issue in the field of educational technologies. It is not enough to prepare learning environments appropriate for individual differences by determining the learning styles with the tests to be applied to the students at the beginning of the learning process. Repeating these tests during the learning process can lead to negative approaches on the students. Villaverde, Godoy & Amandi (2006), state that the use of questionnaires in designing e-learning environments and determining learning characteristics of learners, is time-consuming and inadequate. For these reasons, it is more appropriate for students to perceive their learning styles from the behaviours of e-learning environments in the learning process with the help of artificial intelligence systems. Thus, it will be possible to organize the activities presented to the individuals within the teaching process according to their individual differences. In designing e-learning environments in these properties, it is an important dimension to determine learning styles through artificial intelligence models and students' web usage behaviours.

In this research, Kolb's learning style classification and scales have been used to determine the learning styles of the students. 230 people from the education faculty of Firat University participated in the research. The learning styles have been determined by Kolb's scale before and after the students started using the web-based system prepared within the scope of the research. Learning styles have been examined during the time that students use e-learning environments. The main purpose of this research is to analyze the learning styles used in the e-learning environment with the web usage mining.

The following hypotheses have been tested for this main purpose.

- 1- There is a relationship between the learning styles of the students and the learning tools they use in the e-learning environment.
- 2- The data mining models tested by the researcher accurately predict the learning styles of learners with the appropriate algorithm.

2. Method

The research has been designed according to one of the experimental model “one group pretest-posttest design”. Büyüköztürk, Çakmak, Akgün, Karadeniz and Demirel (2011: 198) point out that the effect of the experimental processes is tested by a study on a single group. The measurements of the one group pretest-posttest dependent variables are obtained using the same measurement tools, pretest and posttest, and the relationship between the mean scores obtained is examined (Balci, 2007: 212).

A preliminary study has conducted with 106 volunteers to test the e-learning environment and the data mining model prepared for the research. It is aimed to preliminarily determine the technical problems that may arise in the process of preliminary study and data collection, also take necessary precautions. At the same time, the scales to be used in the research and the web based system developed for filling these scales have also been tested. Considering the results obtained from the preliminary work and the difficulties encountered, improvements have been made in the infrastructure of the system. In addition, probable data mining models used in the research have been tested. The main study group of the research has been formed from 426 students who were educated at Firat University, Faculty of Education (Mathematics, Turkish, Elementary and Early Childhood Teaching Program) in 2011-2012 academic year. Kolb's learning style inventory (version 3) has been used as pretest and posttest in the data collection process of the research.

Within the framework of the four-week application, all behaviours on the website from the first entry of the students into the e-learning environment until they leave the environment have been recorded in the site logs. Students who complete the study period are required to re-fill the scales after the application as a post-test and they have been asked to fill in the "student opinion form" for their views on the system. A total of 230 users who answered the scales used in the research have been identified. The distribution of these students according to Kolb's style classification as a posttest is as follows; in *Accommodation* 45 (% 19,5), *Diverging* 22 (%9,6) *Assimilating* 22 (%9,6), *Converging* 141 (%61,3). 42.583 records have been used in the analysis processes on 230 user web access logs.

The course contents to be used in the themes determined for the e-learning environment are prepared in accordance with the learning style by the related literature review and expert opinions. Accordingly, for the students to use in e-learning environments, "*Theme Activities*" have been developed separately for each theme and also "*Course Activities*" have been developed separately for each topic. Theme activities include "*discussion, concept map, puzzle and evaluation*" and course activities include "*video, slide show, animation, e-book, topic summary and quiz*".

The duration and frequency of visits of the students in the theme activities and course activities have been determined. It has been observed that there are large differences in the values for the use of student activities in the collected data file and it has been decided to normalize the data records to make them suitable. For this purpose, normalization procedures have been carried out in data records including students' web usage information about the 10 theme-course activities. The normalization process is anticipated as a method preferred by researchers in studies (Villaverde, Godoy, & Amandi, 2006; Hamada, Rashad, & Darwesh, 2011) conducted on this subject. With

normalization, the data sets are evaluated separately for each activity and distributed between -5 and +5. For the visiting duration of web pages, the minimum visiting duration is -5 and the maximum visiting duration is +5. For the visiting frequency of web pages, the minimum visiting frequency is -5 and the maximum visiting frequency is +5. Accordingly, 10 inputs ($X_0 - X_9$) are used in the tested models.

It has been seen that the posttest distributions of the learning styles that make up the output variable of the data mining models haven't been normal and it seems that there is an accumulation in converging style. For this reason, it has been decided to equalize student distributions according to learning styles so that data mining models can work properly. For this purpose, 20 students from each learning style have been randomly selected, and a total of 80 student data have been tested in data mining models. Within the scope of the research, Decision Tree and Artificial Neural Networks models have been applied in accordance with the structure of the data set and the objectives of the research. Data mining models used 70% of the data set as training data and 30% as test data. This data set equals the distributions of learning styles at the output of the data mining models.

2. Findings, Discussion and Results

In general, it is seen that most of the students have a converging learning style according to the pretest and posttest results. This situation seems to be similar when compared to other research (Demir, 2008; Uysal & Yalın, 2009) in Turkey. When we examined the difference between pretest and posttest, there has been a decrease in learning styles that accommodation and converging. It seems that there has been an increase in student number in the diverging and assimilating learning style. This result shows that the experiences of students in e-learning environments and the online learning activities they use affect the learning styles. It is important that there are differences between the results of the students' pretest and posttest even though the same scale is used. This result shows that the systems developed for the adaptation of the web-based learning environments to the individual differences of the students may be insufficient in the application process.

In the data mining analysis, the significance level of the input variables used by the Decision Tree model when constructing the decision diagram varies between 1 and 0.66. The decision diagram uses four inputs: video, animation, abstract and puzzle. The significance of other inputs has been very low importance (near zero). When the success of Decision Tree model of learning the training data is evaluated, it is seen that assimilating and converging learning are 100% successful. It has learned accommodation and diverging learning styles with 50% success. 25% of the training data and 41.8% of the test data have been incorrectly classified according to the results obtained by the Decision Tree model application. These results show that the decision tree model can accurately predict learning style with 58.2% success.

In the ANN model, no special preference is specified for the algorithm to be used. All the algorithms that SAS Enterprise Miner can use have been tested in order. The characteristics of the model are defined in the evaluation of the training data. Accordingly, it has been tried to find the most suitable number of hidden layers by trial and error method. As a result, the number of hidden layers is set to 13. In addition, the maximum iterations have been 50.

ANN model learned learning style 100% successfully. This result has been a direct consequence of the prediction success of the test data. According to the obtained results, the training data has been learned with 100% success in all the algorithms used in the ANN model. However, it is seen that there have been differences according to the algorithms in the classification of test data.

In the literature, it has been seen that many studies have been done to determine learning styles with web usage mining techniques. It is understood that various techniques and algorithms give more successful results according to student data collected in these studies and different e-learning environments (Bousbia, Rebaï, Labat, & Balla, 2010; Liyanage, Gunawardena, & Hirakawa, 2016; Rajper, Shaikh, Shaikh, & Mallah, 2016; Chen & Liu, 2011; Jovanovic, Vukicevic, Milovanovic, & Minovic, 2012). From the perspective of learning styles, these results are thought to contribute greatly to the design of e-learning environments that can be adapted to the individual differences of the learners. In addition, some studies have been carried out to develop web-based tools that automatically detect learning styles of students in web-based learning environments (Sweta & Lal, 2015; Ba-Omar, Petrounias, & Anwar, 2007; Darwesh, Rashad, & Hamada, 2011).

Artificial Neural Networks (ANN) and Decision Tree models have been applied in the studies to determine learning styles of students from web usage behaviours. The duration and frequency of ten learning activities offered to students in the e-learning environment have made up the inputs of data mining models, and learning styles have made up output. When all the results obtained from Decision Tree and ANN models are evaluated, it is understood that ANN model is more successful than Decision Tree model. When the ANN model has been evaluated in terms of its algorithms, the Levenberg-Marquardt algorithm has predicted learning styles of students with success of 91.7%.

As a result of the research, the following suggestions have been developed that will benefit the development of systems that take into account the individual differences of learners in e-learning environments of learning styles.

- It should be taken into consideration that the tests to be performed prior to the learning process in designing web-based environments will not be sufficient to take individual differences into account.
- Data mining models can be used in the framework of adaptive e-learning environments.
- Systems in which learners can predict learning styles from web usage behaviours can be tested with similar models.
- Individual differences can be determined by data mining methods and e-learning environments can be prepared.
- New research using different learning style scales can be done.