

Kitlese Açık Çevrimiçi Kurslardaki Katılımcı Profillerinin Yapay Sinir Ağı Kullanılarak Sınıflandırılması

Ali Al-Taei^{1,2}, Murat Yılmaz², Rory V. O'Connor³, ve Ugur Halici⁴

¹ Bağdat Üniversitesi, Bağdat, Irak
alitaiei@mtu.edu.iq

² Çankaya Üniversitesi, Bilgisayar Mühendisliği, Ankara, Türkiye
myilmaz@cankaya.edu.tr

³ Dublin Şehir Üniversitesi, Bilgisayar Bilimleri Bölümü, Dublin, İrlanda
roconnor@computing.dcu.ie

⁴ Orta Doğu Teknik Üniversitesi, Elektrik ve Elektronik Mühendisliği Bölümü,
Ankara, Türkiye
halici@metu.edu.tr

Özet Son yıllarda, özellikle bilgisayar mühendisliği eğitimi alanında, kitlese açık çevrimiçi kurslara (KAÇK) artan bir ilgi söz konusudur. Bu ilgi bireylerin davranışları, özellikleri ve tercihlerinin anlaşılması önemini altını çizmektedir. Böyle bir anlayış geliştirmek, sıklıkla oyun geliştirme alanında kullanılan kişilik profileme gibi yenilikçi teknikleri uyarlayarak KAÇK tasarım sürecini geliştirmek için çeşitli yollar gerektirmektedir. Bu çalışma, bir kişilik referansı olarak Myers-Briggs Tip Göstergesi (MBTG) kullanılarak katılımcıları (özellikle eksik veri durumlarında) sınıflandırmak için bir yöntem önermektedir. Amaç, KAÇK izleyicileri hakkında ayrıştırıcı bir bakış sunmak için KAÇK katılımcı profillerini MBTG kullanarak araştırmaktır. Bu amaçla, bir bilgisayar mühendisliği kursunda 20 soruluk bir çevrimiçi anket kullanılmıştır: Muhatapların (N=75) cevapları yardımıyla katılımcıların kişilik tipleri belirlenmiştir. Dahası, bir makine öğrenimi modeli bireylerin sınıflandırması için önerilmiştir. Sonuçlar, geri yayımlı (GY) yapay sinir ağının hem eğitim süreci (performans=%100) hem de test süreci için (performans=%93,3) uygun olduğunu göstermiştir. Bu bilgilerin ışığında, yaklaşımımızın MBTG açısından KAÇK katılımcılarının sınıflandırılabilirliklerini araştırmak için kullanılabilir bir yaklaşım olarak kabul edilebilir.

1 Giriş

KAÇK'ların ortaya çıkması bir sonraki on yıl için açık öğrenme kültüründe önemli bir olay olarak değerlendirilebilir [1]. Bunun en önemli nedenlerinden birisi KAÇK'ların kısa bir zaman zarfında belirgin bir başarı kazanmasıdır. KAÇK'lar geniş sayıdaki katılımcılardan, uzman akademiklerden, iyi tanınmış üniversitelerden ve araştırma kuruluşlarından kabul görmüşlerdir [2]. Buna ek olarak, KAÇK'lar, coğrafi sınırlandırmalar, fon sağlama ve katılımcı sayısı

gibi [3,4] kullanılan öğrenme biçimlerinin bir kaçını birden kullanarak ve bağlantıcı pedagojik teknikleri uygulayarak geleneksel çevrimiçi derslerin sınırlarını aşmaktadır [5]. KAÇK'lar başarısı ve bunlara karşı artan ilgi yenilikçi modellerin ve pedagojilerin araştırılmasına yönelik olan kapsamı genişletmektedir [6,7].

Ancak, şimdiye kadar, KAÇK'ların hem tasarlanmasında hem de işletilmesinde karşılaşılabilecek olan pedagojik, teknolojik, lojistik ve finansal problemler hakkında çok az tartışma olmuştur [8]. Pedagojik bakış açısından eğitimler eşzamanlı olarak değişik konumlardaki ve ülkelerdeki belirgin kişilikleri ve farklı hedefleri ve motivasyonları olan büyük bir miktardaki katılımcılarla ilgilenmektedir [4]. Buna ek olarak, araştırmacılara göre, öğrencinin otonomisini arttırmak ve öğrencilerin arasındaki ilişkiyi geliştirmek için yeni öğrenme yaklaşımları keşfedilmektedir [9,10]. Dolayısıyla, KAÇK geliştirme süreçlerinde, farklı kişiliklerin, motivasyonların ve katılımcıların otonomisinin önemli bir rol oynayabileceği hakkında artan bir görüşün olduğu düşünülebilir.

KAÇK'ların sosyal yönlerini incelemek ve araştırmak için, tasarımcıların bir dizi değerlendirme ve araç kullanarak hedef kitleyi detaylı olarak araştırmaları gerekir. MBTG böyle işlemler için kullanılan en yaygın araçlardan birisidir [11]. Genel bir kabul olarak, MBTG ile sınıflandırılmış, aynı kişilik tipi kategorisindeki bireyler benzer karakteristiklere sahiptir ve olaylar karşısında benzer şekilde davranırlar. Daha farklı bir ifadeyle, her bir kişilik tipi bağımsız (benzersiz) bir davranış kalıbını temsil eder. Ayrıca, yazarlar, bu sınıflandırma ile kalıpları inceleyen, makine öğrenme tekniklerini kullanılmasının uygun olabileceğini düşünmektedir. Örneğin, bu tür yaklaşımlar karmaşık yapay davranışsal modeller oluşturmak için kullanışlı olabilirler [12].

Bu araştırmanın temel amacı, KAÇK'ların katılımcılarında MBTG değerlendirmesini kullanarak kişilik karakteristiklerini incelemektir. Diğer bir deyişle, bu çalışma sırasında kişilik tiplerinden elde edilen bilgileri kullanarak bireylerin ilgili kişilik tiplerine göre sınıflandırılması araştırılacaktır. MBTG aracı yardımı ile toplanan bilgilerin ışığında KAÇK katılımcılarının kişilik tiplerini - özellikle eksik veri durumlarında - ortaya çıkarmak için bir geri yayımlı (GY) yapay sinir ağı sınıflandırıcısı kullanılacaktır.

Bu araştırma aşağıdaki araştırma sorularına (AS) yanıt vermeyi hedefler:

AS1: *KAÇK katılımcılarını öznel karakteristiklerine (örn. kişilik tipleri) göre sınıflandırmak mümkün müdür?*

AS2: *KAÇK katılımcılarını (özellikle eksik veri durumlarında) geri yayımlı (GY) yapay sinir ağı kullanarak, kişilik tiplerine bağlı ve otomatik olarak sınıflandırmak mümkün müdür?*

Bu makalenin kalanı aşağıdaki gibi organize edilmiştir: Kısım ikide çalışmanın arka planını detaylandırılacaktır. Özellikle MBTG değerlendirmesi için literatür özetlenecek, geri yayımlı (GY) algoritmaya sahip olan çok katmanlı algıyı (ÇKA) ve ilgili çalışmalarından örnekler verilecektir. Titiz bir yaklaşım üzerine inşa edilmiş olan üçüncü kısım, araştırma sürecini açıklamaktadır. Makalenin devamında kurgulanan çalışmaların sonuçları tartışılmıştır. Son olarak, makale sonuçların ve gelecekteki çalışmaların açık bir özetiyle son bulmaktadır.

2 Araştırmanın Temelleri

2.1 Myers ve Briggs Kişilik Tipleri

Kişilik bireylerin davranış biçimlerindeki ölçülebilir farklılıkları oluşturan faktörlerin sınıflandırılması ile meydana geldiği kabul edilen, bireylere ait bir sosyal kurgudur. MBTG kişilik tiplerinin ortaya çıkartılması için düşünülmüş bir araçtır. Bu araç yardımı ile bireylerin belli ayrıçlara verdikleri cevaplar doğrultusunda kişilik tipinin tespit edilmesi ilkesine dayanır.

Tablo 1’de MBTG için tanımlanmış olası kişilik tipi ayrıçları görülmektedir.

Dışa dönük (E)	(I) İçe Dönük
Duyusal (S)	(N) Sezgisel
Düşünen (T)	(F) Hisseden
Yargılayıcı (J)	(P) Algılayıcı

Tablo 1. Myers ve Briggs Kişilik Tipleri

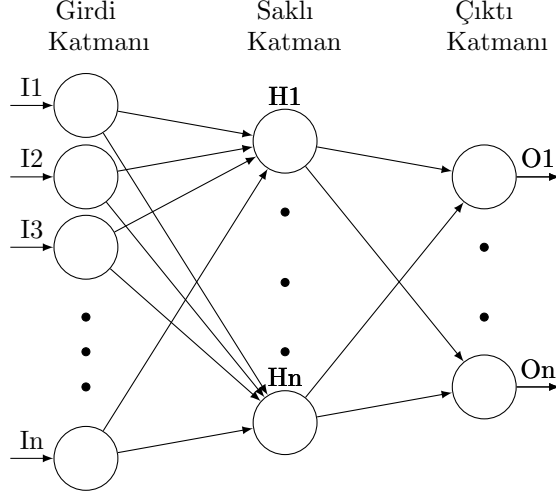
MBTG’ye göre, iki kutuplu olarak sınıflandırılmış kişilik tipleri (i) enerji toplama, (ii) algısal motor becerileri, (iii) karar verme, ve (iv) yaşama biçimleri ile tanımlı dört ayrı belirteç yardımı ile incelenebilir [11]: Dışadönüklük - İçedönüklük (E-I) kişilerin sosyal aktivitelere olan ilgiyi, Duyusal - Sezgisel (S-N) bireylerin çevreyi algılama şekillerini, Düşünme-Hissetme (T-F) bireylerin karar verme mekanizmalarını ve son olarak Yargılama - Algılama (J-P) bireylerin yamsal tercihlerini (örn. çok planlı olma veya hızlı adapte olma) belirler.

2.2 Çok Katmanlı Algılayıcı

Çok katmanlı algılayıcı⁵ (ÇKA) karmaşık örüntülerin sınıflandırılması konusundaki yüksek veriminden dolayı, en sıkça kullanılan ve yapay sinir ağı yöntemlerinden bir tanesidir. ÇKA algılama modeli, bağlantılı üç ana katman yapısından oluşur: giriş katmanı, bir (ya da daha fazla) saklı katman ve çıkış katmanı. Bu katmanlar ağırlıklı bağlantılarla birbirine bağlıdır. Katman k’daki her bir düğüm girişini bir önceki katmandan alır. Bu giriş değerleri ağırlıklı olarak toplandıktan sonra bir çıkış fonksiyonundan geçirilerek her bir düğümün çıkış değerleri elde edilir. Giriş katmanındaki düğümlerin sayısı giriş vektöründeki özelliklerin sayısına eşittir. Saklı katman sayısı ve bu katmanlardaki düğüm sayıları değişken parametreler olduğundan tasarımcıya bağlıdır ve daha yüksek verim için dikkatlice tasarlanmalıdır. ÇKA örüntü tanımada kullanıldığında, çıkış katmanındaki her bir düğüm bir sınıfı temsil edecek şekilde tasarlanır [13].

Genel olarak GY algoritması kullanılan ÇKA modellerinde, öğrenme kümelerindeki örneklere ait giriş verileri tek tek giriş katmanına uygulanarak çıkış katmanına kadar düğüm çıktıları hesaplanır. Çıkış katmanındaki tüm düğümler

⁵ Multi Layer Perceptron



Şekil 1. Tipik tek bir saklı katmana sahip ÇKA yapay sinir ağı modeli. $\{I_1, I_2, I_3 \dots I_n\}$, girdi katmanını, $\{H_1, \dots H_n\}$, saklı katmanı, $\{O_1, \dots O_n\}$, ise çıktı katmanını göstermektedir.

için gerçek çıktı ve öğrenme kümesinden uygulanan örnek için belirlenen çıktı arasındaki farka bakılarak hata hesaplanır ve bu hatayı azaltmak üzere her bir düğüm arasındaki bağlantı kuvvetleri her bir örnek üzerinden dögünlü olarak düzeltilir [13].

2.3 Kişilik Tabanlı Sınıflandırma Literatürü

Bireylerin karakterleri, motivasyon ve kişisel tercihleri gibi psikometrik özelliklerinin araştırması yapılmış olup bu özellikler yazılım mühendisliği [16], oyun geliştirme [17] ve ekonomi dersleri [18] gibi pek çok farklı disiplinlerde kullanılmıştır. MBTG [11], Keirseyn mizaç sınıflayıcısı [19] gibi farklı yöntemler, katılımcıların kişilik tiplerini değerlendirmek için kullanılmıştır.

Mairesse ve diğerleri [20], yazışma ve konuşma yoluyla otomatik olarak kişiliği tahmin etmek amacıyla sözel ipuçlarını kullanmışlardır. Önerilen yöntem, bireylerin konuşma ve yazışmalarına, gözlemsel olarak değerlendirilen kişilik öz sınımalarına bağlı olarak BigFive kişilik özelliklerini keşfetmeye dayanıyordu. Aynı şekilde, destek vektör makinesi, karar ağacı (KA) ve en yakın komşu (EYK)

gibi deęişken yöntemler üç farklı modelin (üç adet makineli öğrenme yaklaşımı kullanılmıştır: sınıflandırma algoritmaları, regresyon ve sıralama) performansını denemek amacıyla kullanılmıştır. Genel olarak, sonuçlar sıralama model performanslarının yüksek olduğunu göstermektedir. Ayrıca, gözlemlenen kişilik veri kümesi kullanılarak yapılan sınıflama model performanslarının, öz kişilięi derecelendirmesinin kullanılarak yapılmış olan modellerden daha yeterli bulunduğu tespit edilmiştir. Buna ek olarak, kişilik özelliklerinin karakter seti çıkarımı açısından en önemli faktör olduğu gözlenmiştir.

Celli ve dięerleri [21] Facebook kullanıcılarının ($N = 100$) profil resimlerine ve öz-deęerlendirme BigFive özelliklerinin kişilik testine dayalı olarak kişilik tipi ile etkileşim tarzının tanınması amacıyla destek vektör makinesi, yapay sinir aęları, karar aęacı, naif bayes, lojistik regresyon ve kural öğrenimi gibi altı farklı makineli öğrenme yöntemini test etmişlerdir. Özellik çıkarma işlemi görsel-kelimeler-çantası (GKÇ) teknięi ile gerçekleştirilmiştir. Sonuçlar, her bir sınıflandırıcı doğruluğunun kişilik özelliklerine baęlı olduğunu göstermektedir. Bu çalışmada elde edilen ortalama performans ise % 66,5 olmuştur.

Cowley ve dięerleri [22] oyun deneyimi ve oyuncu kişilik tipini keşfetmek için makine öğrenme yöntemlerinin kullanılmasının emekleme döneminde olduğuna değinmiştir. Çalışmalarında, sınıflama için uygun kuralların seçilmesi amacıyla karar aęacı metodunun iki çeşidini (yani CART ve C5.0) ve Pac-Man oyuncuları üzerinde oyuncu taksonomisine göre eğitmişlerdir. Eğitim seti 100 olayı, test seti ise 37 olayı içermiştir. Bu çalışmada sınıflandırıcının test performansı doğrulaması yaklaşık % 70 olmuştur.

Aruan ve dięerleri [23] birden fazla kullanıcı için uygun olan bir sanal öğretmen ajanı ve çok oyunculu online oyunlardan esinlenerek ortak alanlarda probleme dayalı öğrenme yöntemi geliştirmişlerdir. Arayüz destekli ortak alan ve devasa çok oyunculu çevrim içi oyunu bakış açısından, kullanıcılar ile ilgili teknolojik konular kullanılarak öğrenmenin iki farklı konusu birleştirilmiştir. Buna ek olarak, bazı uygulamalar ve kodlama amaca ulaşmak için kullanılmış olup elde edilen sonuçlar kabul edilebilir olmuştur.

Golbeck ve dięerleri [24] Twitter kullanıcılarının kişiliklerini tahmin etmek için bir model önermişlerdir. Bu model, Twitter kullanıcıları ve BigFive kişilik testi profillerinde kamuya açık bilgilere dayandırılmıştır. Özellikle, BigFive testi kullanıcılarının 279 adedine uygulanmış ve onların en yaygın 2000 tweetleri toplanmıştır. Daha sonra karakter, metin çözümleme aracı ile veri çıkarılmıştır. Son olarak, iki regresyon yöntemi (Gauss işlemi ve ZeroR) kişilik tahmini için kullanılmıştır. Sonuçlar her iki yöntem de aynı şekilde gerçekleştirildięi ve doğruluklarının makul olduğunu göstermektedir.

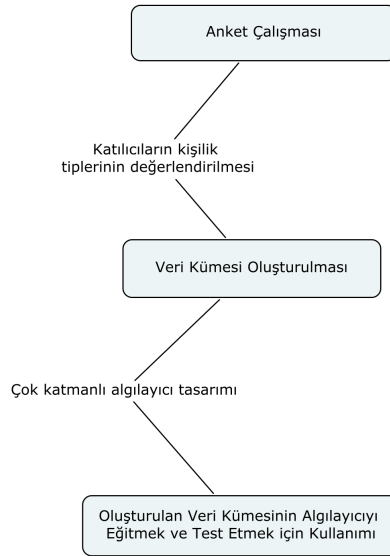
Lotte ve dięerleri [14] bir dizi en yaygın kullanılan sınıflandırma yöntemlerini (destek vektör makinesi (DVM), çok katmanlı algılayıcı (ÇKA), vb.) gözden geçirmiş ve elektro-ensefalo-grafisi (EEG) veri kümesini kullanarak beyin-bilgisayar arayüzü (BBI) için uygun sınıflandırma algoritmaları bulmak için performansları karşılaştırmışlardır. Her bir sınıflandırıcının sonuçları ve etkinlięi analiz edilmiş ve belirli bir görev için uygun sınıflandırıcı seçerken kabul edilebilir bilginin somut bir tavan sunmak için dięer sınıflandırıcılar arasında karşılaştırılmıştır.

Genel olarak, EEG veri kümesini kullanarak BCI alanı için DVM'nin diğer sınıflandırıcılara göre daha iyi performans sergilediği tespit edilmiştir. Bununla beraber, sinir ağlarının genel olarak BCI alanında araştırmada kullanılması gibi ÇKA performansı da bu görev için kabul edilebilir olmuştur.

Katılımcıların kişiliklerini tespit etmek için özellikle KAÇK üzerinde yapılan çalışmalar sınırlıdır. Ayrıca, şimdiye kadar kişilik tiplerinin otomatik olarak sınıflandırılması için çok az çalışma yapılmıştır. (örn. [20]).

3 Yöntem

Bu çalışmada kullanılan yaklaşım üç ana adımdan oluşur. İlk adımda, bireylerin kişilik tiplerini değerlendirmek için bir anket çalışması yapılmıştır. Amaç, MBTG aracını kullanarak katılımcıların kişilik tipini ortaya koymaktır. İkinci aşamada, birinci adımda elde edilen sonuçlara göre bir veri kümesi üretilmiştir. Üçüncü aşamada, bu veri kümesi kişilik tiplerinin bir GY algoritmali (yapay sinir ağı temelli) çok katmanlı kişilik sınıflandırıcısını eğitmek ve test etmek için kullanılmıştır (bkz. Şekil 2).



Şekil 2. Araştırmada Kullanılan Yöntem Adımları.


Bu çalışmanın ana varsayımı, davranışların temel psikolojik modellerin araştırılabilir ve bir GY algoritmali ÇKA kişilik sınıflandırıcısını eğitmek için kullanılabilir olmasıdır. Veriler, katılımcıların (N=75) kişilik tercihlerini keşfetmek için 20 soru içeren bir anket vasıtasıyla toplanmıştır.

Özellikle, KAÇK katılımcılarını otomatik olarak ilgili kişilik tipi içinde sınıflandırmak amacıyla makine öğrenme yöntemlerinin uygun bir sınıflandırıcı modelini eğitmek ve test etmek için kullanılması yeni bir tür yaklaşımdır. MBTG testinin bir versiyonunu anket katılımcıları tarafından cevaplanmak üzere dağıtılmıştır. MBTG test katılımcılarının cevapları kullanılarak ve 20 cevap girdisi ana özellikler olarak (örneğin; E-I, S-N, T-F ve J-P) 4 adet kişilik tipi ayraçları içinde normalize edilerek güvenilir bir veri kümesi oluşturulması hedeflenmiştir.

Bütün bunlara ek olarak, kişilerin davranış profillerinin daha iyi anlaşılması ve sınıflandırılabilmesi için çok katmanlı algılayıcı (ÇKA) bir makine sınıflandırması sınıflandırma yöntemi kullanılmıştır. ÇKA'nın başarılı bir şekilde katılımcı profillerini sınıflandırabilmesi için, toplanan veri seti, klasik yöntemler ışığında; eğitim seti (olayların % 80'i) ve test seti (olayların % 20'i) olmak üzere iki ayrı parça haline işleme sokulmuştur.

Tasarlanan GY algoritmali ÇKA'nın farklı mimari yapıları ve olası parametreleri en verimli modeli bulmak için incelenmiştir⁶. GY tabanlı ÇKA, her bir MBTG kişilik tipi için tanımlanmış, dört adet girdi katmanı düğümünden oluşmaktadır. Çıktı katmanı her bir düğümü tek bir kişilik tipini gösteren onaltı adet düğüm içermektedir.

Şekil 3. Önerilen GY-tabanlı kişilik tipleri sınıflandırıcı mimarisini göstermektedir.



Şekil 3. GY-tabanlı kişilik tipleri sınıflandırıcı mimarisini.

⁶ Öğrenen GY algoritmali ÇKA'nın yaklaşık hata kareler ortalamasının karekökü 0.09'den daha az ya da eşit olmalıdır

4 Tartışmalar

Çalışmanın ilk aşamasında katılımcıların MBTG yardımı ile kişilik tipleri belirlenmiştir. Çalışmanın ilk kısmında yapılan test sonucunda elde edilen MBTG kişilik tipleri Tablo 2’de gösterilmiştir.

ISTJ %13.3 (N=10)	ISFJ %4 (N=3)	INFJ %2.6 (N=2)	INTJ %8 (N=6)
ISTP %2.6(N=2)	ISFP %1.3 (N=1)	INFP %2.6 (N=2)	INTP %1.3 (N=1)
ESTP %6.6 (N=5)	ESFP %4 (N=3)	ENFP %4 (N=3)	ENTP %12 (N=9)
ESTJ %14.6 (N=11)	ESFJ %4 (N=3)	ENFJ %6.6 (N=5)	ENTJ %12 (N=9)

Tablo 2. MBTG tiplerine göre katılımcıların dağılımı ($N_{toplam} = 75$)

Elde edilen sonuçlar ışığında çalışmanın devamında GY öğrenme tabanlı bir çok katmanlı algılayıcı kişilik tipleri sınıflandırıcısı olarak eğitilmiştir. Toplanan verilerin 60 tanesi algılayıcının eğitilmesi için kullanılmıştır. Çarpaz gerçekleştirme tekniği ($k=10$) yardımı ile otomatik öğrenme süreci sırasında oluşabilecek fazla eğitim (veri ile model arasında oluşabilecek aşırı uyum) engellenmiş, bu sayede elde edilen model görmediği durumlar içerisinde genelleştirme yeteneğini kaybetmemesi sağlanmıştır.

Elde edilen sınıflandırma sonuçları Tablo 3 yanılma matrisi olarak sunulmuştur.

Testler sırasında modelin performansı %93.3 olarak bulunmuştur. Test için kullanılan 14 olay doğru olarak, bir tanesi yanlış olarak sınıflandırılmıştır. Ayrıca, hata kareler ortalamasının karekökü 0.08 olarak hesaplanmıştır.

Testler sırasında çok katmanlı sınıflandırıcının performansı %93.3 olarak belirlenmiştir. Sınıflandırıcıda ayrıca on adet saklı katman, öğrenme oranı=0.2, momentum=0.3, ve epoch=500 olarak gözlenmiştir. Bu bilgilerin ışığında geri yayımlı çok katmanlı algılayıcının iyi bir performans gösterdiği kabul edilebilir. Bu sonuçlar, otomatik yazı veya diyalog tabanlı kişilik algılayıcılardan [20] daha iyi sonuçlar vermektedir. Bunun yanı sıra elde edilen sonuçlar geri yayımlı çok katmanlı algılayıcılar ile yapılan bazı çalışmalara yakın sayılabilir.

4.1 Kısıtlamalar

Kişilik testlerine bağlı olan araştırmalar bireylerin karakteristikleri ile ilgili kesin delil elde etmek yerine kişilerin tercihleri ile ilgili fikir elde etmeyi amaçlar. Bununla birlikte, elde edilen sonuçlar, yapılan testlerde kişilerin kendi karakterlerine en uygun cevabı seçtiği kabulüne dayanır. Ayrıca yapay sinir ağları veya benzeri

a b c d e f g h i j k l m n o p	<- sınıflandırılmış şekli
1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	a = ISTJ
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	b = ISFJ
0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	c = INFJ
0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	d = INTJ
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	e = ISTP
0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	f = ISFP
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	g = INFP
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	h = INTP
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	i = ESTP
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	j = ESFP
0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0	k = ENFP
0 0 0 0 0 0 0 0 0 0 0 0 3 0 0 0 0 0 0 0	l = ENTP
0 0 0 0 0 0 0 0 0 0 0 0 0 4 0 0 0 0 0 0	m = ESTJ
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	n = ESFJ
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0	o = ENFJ
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 2 0	p = ENTJ

Tablo 3. Sınıflandırıcının yanılma matrisi.

öğrenme metotları ile elde edilen sonuçların veri tabanlı hazırlama, verinin büyüklüğü, eğitim ve test kümelerinin kalitesi gibi parametrelerden etkilendiği gözlenmiştir. Tüm bu kısıtlamalara rağmen çalışma sonucunda elde edilen sonuçlar ışığında, seçilen örneklemin, örnek popülasyonu temsil ettiği kabul edilebilir.

5 Sonuçlar ve Gelecek Çalışmalar

Bu çalışmada kitlesel açık çevrim içi kurslara katılan bir grup katılıcı kullanıcılar olarak bireylerin kişilik profilleri elde edilmiştir. Daha sonra, bu bilgiler ışığında geri yayımlı çok katmanlı algılayıcı modeli kullanılarak bu tip kurslardaki katılımcıların sınıflandırılması sağlanmıştır. Yapay sinir ağı eksik veri ışığında bireylerin kişilik tiplerini öngörmektedir. Bu tip çalışmalar ile elde edilecek bilgi yardımıyla, katılımcıların ilgi alanları, eğitsel içerik ve kendilerine sunulabilecek modüller arasında dinamik bir bağlantı kurulabilecektir. Bu bağlantı sayesinde, katılımcıların kişilik profillerine göre şekillendirilmiş dinamik bir eğitim yapısı kurgulanması ve sunulması imkanından söz edilebilmektedir. Böylelikle, kişilerin öğrenme stillerine uygun ve bireysel motivasyonlarını yitirmelerini engelleyecek bir mekanizma tasarlanabilecektir.

Araştırmanın başında sunduğumuz araştırma sorularına geri dönecek olursak farklı kişilik tiplerindeki katılımcıların öznel karakteristiklerine uygun olarak sınıflandırılması ve eksik veri durumlarında da bu örüntü sınıflarının gözlenebilirliği ile ilgili önemli bir adım atılmıştır. Elde edilen örüntüler sayesinde gelecek çalışmalar, kişileri KAÇK'larda en uygun sınıflara yerleştirebilme ve onlara potansiyel çalışma şekilleri ile ilgili çeşitli önerilerde bulunabilme gibi önemli faydalar getirecektir.

KAÇK'larda gözlenen devamsızlık diğer online sistemlerden farklı bir gelişim süreci izlemektedir. Önerdiğimiz yenilikçi yaklaşım sayesinde, kitlesel açık çevrim içi kurslardaki en büyük sorunlardan biri olan sürdürülebilirlik probleminin çözümü için bir ön hazırlık çalışması oluşturulmuştur. Sunulan sınıflandırma modeli, makine-tabanlı uyarlamalı bir öğrenme ortamı kurgusu için temel teşkil edecektir. Sınıflandırıcı, ilk testlerinde, %10 eksik veri ile %100 başarı ile çalışmaktadır. KAÇK Öğrencilerinin al-ve-kaç doğasına daha uygun bir hizmet verebilmek için kişilik profillerinin önerilen tanı sistemi ile belirlenmesi bu bireylerin öğrenme ihtiyaçlarının karşılanması için atılmış olan önemli bir adımdır.

Kaynaklar

1. Ehlers, U.D.: Open Learning Cultures: A Guide to Quality, Evaluation, and Assessment for Future Learning. Springer (2013)
2. Mota, R., Scott, D.: Education for Innovation and Independent Learning. Elsevier (2014)
3. Severance, C.: Teaching the world: Daphne koller and coursera. *Computer* **45** (2012) 8–9
4. Hill, P.: Online educational delivery models: A descriptive view. <http://www.educause.edu/ero> (2014)
5. Siemens, G.: Moocs are really a platform. Elearnspace blog: <http://www.elearnspace.org/blog/2012/07/25/moocs-are-really-a-platform> (2012)
6. Kolowich, S.: How will moocs make money. *Inside Higher Ed* (2012)
7. Martin, F.G.: Will massive open online courses change how we teach? *Communications of the ACM* **55** (2012) 26–28
8. McAuley, A., Stewart, B., Siemens, G., Cormier, D.: The mooc model for digital practice (2010)
9. Downes, S.: The role of the educator (2010)
10. Kop, R., Fournier, H., Mak, J.S.F.: A pedagogy of abundance or a pedagogy to support human beings? participant support on massive open online courses. *The International Review of Research in Open and Distance Learning* **12** (2011) 74–93
11. Myers, I.B., McCaulley, M.H., Most, R.: Manual: A guide to the development and use of the Myers-Briggs Type Indicator. Consulting Psychologists Press Palo Alto, CA (1985)
12. Minsky, M.: The emotion machine. New York: Pantheon (2006)
13. Hagan, M.T., Demuth, H.B., Beale, M.H., et al.: Neural network design. Volume 1. Pws Boston (1996)
14. Lotte, F., Congedo, M., Lécuyer, A., Lamarche, F., Arnaldi, B., et al.: A review of classification algorithms for eeg-based brain–computer interfaces. *Journal of neural engineering* **4** (2007)
15. Azadeh, A., Rouzbahman, M., Saberi, M., Mohammad Fam, I.: An adaptive neural network algorithm for assessment and improvement of job satisfaction with respect to hse and ergonomics program: The case of a gas refinery. *Journal of Loss Prevention in the Process Industries* **24** (2011) 361–370
16. Yilmaz, M.: A software process engineering approach to understanding software productivity and team personality characteristics: an empirical investigation. PhD thesis, Dublin City University (2013)
17. Novak, J.: Game development essentials: an introduction. Cengage Learning (2011)

18. Borg, M.O., Stranahan, H.A.: Personality type and student performance in upper-level economics courses: The importance of race and gender. *The Journal of Economic Education* **33** (2002) 3–14
19. Keirsey, D.: *Please Understand Me II: Temperament, Character, Intelligence* Author: David Keirsey, Publisher: Prometheus Nemesis Book C. Prometheus Nemesis Book Co (1998)
20. Mairesse, F., Walker, M.A., Mehl, M.R., Moore, R.K.: Using linguistic cues for the automatic recognition of personality in conversation and text. *Journal of artificial intelligence research* (2007) 457–500
21. Celli, F., Bruni, E., Lepri, B.: Automatic personality and interaction style recognition from facebook profile pictures. In: *Proceedings of the ACM International Conference on Multimedia*, ACM (2014) 1101–1104
22. Cowley, B., Charles, D., Black, M., Hickey, R.: Real-time rule-based classification of player types in computer games. *User Modeling and User-Adapted Interaction* **23** (2013) 489–526
23. Aruan, F., Prihatmanto, A., Hindersah, H., et al.: The designing and implementation of a problem based learning in collaborative virtual environments using mmog technology. In: *System Engineering and Technology (ICSET), 2012 International Conference on*, IEEE (2012) 1–7
24. Golbeck, J., Robles, C., Edmondson, M., Turner, K.: Predicting personality from twitter. In: *Privacy, Security, Risk and Trust (PASSAT) and 2011 IEEE Third International Conference on Social Computing (SocialCom), 2011 IEEE Third International Conference on*, IEEE (2011) 149–156