

Yıl:2019

Cilt:3:

Sayı:1

Year:2019

Vol:3

No:1

UYBİSBBD

ULUSLARARASI YÖNETİM BİLİŞİM SİSTEMLERİ
VE
BİLGİSAYAR BİLİMLERİ DERGİSİ

ULUSLARARASI INTERNATIONAL JOURNAL OF
YÖNETİM MANAGEMENT
BİLİŞİM SİSTEMLERİ INFORMATION SYSTEMS
VE AND
BİLGİSAYAR BİLİMLERİ DERGİSİ COMPUTER SCIENCE

Cilt: 3 • Sayı: 1 • Haziran 2019
Vol: 3 • No: 1 • June 2019

**ULUSLARARASI YÖNETİM BİLİŞİM SİSTEMLERİ
VE
BİLGİSAYAR BİLİMLERİ DERGİSİ**

**INTERNATIONAL JOURNAL OF MANAGEMENT INFORMATION SYSTEMS
AND
COMPUTER SCIENCE**

Cilt: 3 • Sayı: 1 • Haziran 2019

Vol: 3 • No: 1 • June 2019

Dergi Sahibi (Owner)

Öğr.Gör. Adem KORKMAZ

Baş Editör (Editor-in-Chief)

Dr. Tarık TALAN

Editörler (Editors)

Dr. Öğr. Üyesi Mustafa Mikail ÖZÇİLOĞLU

Dr. Öğr. Üyesi Ayşe ÇİÇEK KORKMAZ

Dr. Tarık TALAN

Öğr.Gör. Selma BÜYÜKGÖZE

Yayın Kurulu (Editorial Board)

Prof. Dr. Florentin SMARANDACHE

Dr. Öğr. Üyesi Mustafa Mikail ÖZÇİLOĞLU

Dr. Öğr. Üyesi Ayşe ÇİÇEK KORKMAZ

Dr. Tarık TALAN

Dr. Bogdan PATRUT

Dr. Iulian FURDU

Dr. Sadiq HUSSAIN

Dr. Svitlana ILNYTSKA

İngilizce Dil Editörleri

(English Language Editors)

Okt. Abdil Celal YAŞAMALI

Okt. Emrah PEKSOY

Danışma Kurulu (Advisory Board)

Prof. Dr. Abdulkadir YILDIZ (Kahramanmaraş Sütçü İmam Üniversitesi)

Prof. Dr. Erdem UÇAR (Trakya Üniversitesi)

Prof. Dr. Florentin Smarandache (University of New Mexico)

Prof. Dr. H. Mustafa PAKSOY (Kilis 7 Aralık Üniversitesi)

Prof. Dr. İsmail Rakıp KARAŞ (Karabük Üniversitesi)

Prof. Dr. Kani ARICI (Kilis 7 Aralık Üniversitesi)

Prof. Dr. Nazım ŞEKEROĞLU (Kilis 7 Aralık Üniversitesi)

Prof. Dr. Sadettin PAKSOY (Kilis 7 Aralık Üniversitesi)

Prof. Dr. Sevinç GÜLSEÇEN (İstanbul Üniversitesi)

Prof. Dr. Ülkü BAYKAL (İstanbul Üniversitesi)

Prof. Dr. Yılmaz Kılıçaslan (Adnan Menderes Üniversitesi)

Doç. Dr. Ercan BULUŞ (Tekirdağ Namık Kemal Üniversitesi)

Doç. Dr. Erdiñ UZUN (Tekirdağ Namık Kemal Üniversitesi)

Doç. Dr. İlhan UMUT (Trakya Üniversitesi)

Doç. Dr. Mustafa ŞEKKELİ (Kahramanmaraş Sütçü İmam Üniversitesi)

Doç. Dr. Yusuf Ekrem AKBAŞ Adıyaman Üniversitesi)

Adres (Address)

Kilis 7 Aralık Üniversitesi

Teknik Bilimler Meslek Yüksekokulu

79100 Kilis / TÜRKİYE

E-mail : ybsbb.info@gmail.com

Web : dergipark.gov.tr/uybisbbd

HAKEM KURULU

Prof. Dr. Abdulkadir YILDIZ (Kahramanmaraş Sütçü İmam Üniversitesi)	Dr. Öğr. Üyesi Zülfiye BIKMAZ (Kırklareli Üniversitesi)
Prof. Dr. H. Mustafa PAKSOY (Kilis 7 Aralık Üniversitesi)	Dr. Öğr. Üyesi Ö. Fatih KEÇECİOĞLU (Kahramanmaraş Sütçü İmam Üniversitesi)
Prof. Dr. Mustafa AKSU (İstanbul Üniversitesi)	Dr. Öğr. Üyesi Cuma ERCAN (Kilis 7 Aralık Üniversitesi)
Prof. Dr. Sadettin PAKSOY (Kilis 7 Aralık Üniversitesi)	Dr. Öğr. Üyesi Mustafa Oğuz GÖK (Kahramanmaraş Sütçü İmam Üniversitesi)
Doç. Dr. Deniz Mertkan GEZGİN (Trakya Üniversitesi)	Dr. Öğr. Üyesi Sinan UĞUZ (Isparta Uygulamalı Bilimler Üniversitesi)
Doç. Dr. İlhan UMUT (Trakya Üniversitesi)	Dr. Öğr. Üyesi Muhammet ATALAY (Kırklareli Üniversitesi)
Doç. Dr. İrfan Deli (Kilis 7 Aralık Üniversitesi)	Dr. Öğr. Üyesi Mustafa Mikail ÖZÇİLOĞLU (Kilis 7 Aralık Üniversitesi)
Doç. Dr. Nursal ARICI (Gazi Üniversitesi)	Dr. Öğr. Üyesi Hasan Hüseyin ÇAM (Kilis 7 Aralık Üniversitesi)
Doç. Dr. Yusuf Ekrem AKBAŞ (Adıyaman Üniversitesi)	Dr. Öğr. Üyesi Ebru KÜLEKÇİ AKYAVUZ (Kilis 7 Aralık Üniversitesi)
Prof. Dr. Kemal Delihacıoğlu (Kilis 7 Aralık Üniversitesi)	Dr. Öğr. Üyesi Halil ARSLAN (Cumhuriyet Üniversitesi)
Dr. Öğr. Üyesi Bengü HIRLAK (Kilis 7 Aralık Üniversitesi)	Dr. Öğr. Üyesi Emrah AYDEMİR (Ahi Evran Üniversitesi)
Dr. Öğr. Üyesi Edip Serdar GÜNER (Kırklareli Üniversitesi)	Dr. Öğr. Üyesi Ayşe ÇİÇEK KORKMAZ (Bandırma 17 Eylül Üniversitesi)
Dr. Öğr. Üyesi Hüseyin KOÇARSLAN (Selçuk Üniversitesi)	Dr. Öğr. Üyesi Hüseyin AKAR (Kilis 7 Aralık Üniversitesi)
Dr. Öğr. Üyesi Yasin ORTAKCI (Karabük Üniversitesi)	Dr. Nilüfer VATANSEVER TOYLAN (Kırklareli Üniversitesi)
Dr. Öğr. Üyesi Mehmet ÖZÇALICI (Kilis 7 Aralık Üniversitesi)	Dr. Murat GEZER (İstanbul Üniversitesi)
Dr. Öğr. Üyesi Melda AKBABA (Kilis 7 Aralık Üniversitesi)	Dr. Serra Çelik (İstanbul Üniversitesi)
Dr. Öğretim Üyesi Hayrettin TOYLAN (Kırklareli Üniversitesi)	Dr. Feyzi KAYSİ (İstanbul Üniversitesi)
Dr. Öğr. Üyesi Yasin SÖNMEZ (Dicle Üniversitesi)	Dr. Hakan AÇIKGÖZ (Kilis 7 Aralık Üniversitesi)
Dr. Öğr. Üyesi Ramazan ASLAN (Adıyaman Üniversitesi)	Dr. Fatma Önay KOÇOĞLU (İstanbul Üniversitesi)
Dr. Öğr. Üyesi Sibel YAŞAR (Kırklareli Üniversitesi)	Dr. Fatih AYDIN (Kırklareli Üniversitesi)
Dr. Öğr. Üyesi Şebnem ÖZDEMİR (Beykent Üniversitesi)	Dr. Cemal AKTÜRK (Kilis 7 Aralık Üniversitesi)

Dr. Öğr. Üyesi ALİ DURDU
(Ankara Sosyal Bilimler Üniversitesi)

Dr. Tarık TALAN
(Kilis 7 Aralık Üniversitesi)

Dr. Öğr. Üyesi Hakan ÜSTÜNEL
(Kırklareli Üniversitesi)

Dr. Ahmet Çağdaş SEÇKİN
(Uşak Üniversitesi)

Dr. Öğr. Üyesi Mehmet BAKIR
(Bozok Üniversitesi)

Dr. Emre AKADAL
(İstanbul Üniversitesi)

YAYIN POLİTİKASI

Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi yılda iki kez Haziran ve Aralık aylarında yayınlanan uluslararası hakemli bir dergidir. Dergide yer alan yazılar kaynak gösterilmeksizin kısmen ya da tamamen iktibas edilemez. Bu dergide yayınlanan çalışmaların bilim ve dil sorumluluğu yazarlarına aittir.

Dergimize gönderilen çalışmalar, alanında uzman iki ayrı hakem tarafından incelendikten sonra uygun görülenler yayınlanmaktadır. Yazım kurallarına ilişkin bilgilere dergimizin web adresinde yer verilmiştir. Bu derginin tüm hakları saklıdır. Önceden yazılı izin almaksızın hiçbir iletişim ve kopyalama sistemi kullanılarak yeniden kopyalanamaz, çoğaltılamaz ve satılamaz.

International Journal of Management Information Systems and Computer Science is an international peer-reviewed journal which is published two times a year in June and December. The articles cannot be cited partly or entirely without showing resources. The responsibility about scientific and grammatical issues is belong to authors.

The papers sent to the journal are reviewed by two referees and after their approval, they will be sent to edit before being published. Writing & Publishing Policies can be found in the journal's website. All rights reserved. No part of this publication may be reproduced, stored or introduced into a retrieval system without prior written permission.

Makaleler / Articles

Türkiye'deki Ortaokulların Verimliliklerinin Veri Zarflama Yöntemi İle Analizi

Data Envelopment Analysis For Measuring The Efficiency Of Secondary Schools In Turkey

Makale Türü: Araştırma Makalesi / Paper Type: Research Paper

Yahya ÖZDEMİR & Ali DEMİR & Hasan Önal SEYHANLIOĞLU

1-10

Saldırı Tespit Sistemlerine Makine Öğrenme Etkisi

The Effect Of Machine Learning On Intrusion Detection Systems

Makale Türü: Araştırma Makalesi / Paper Type: Research Paper

Çağdaş ÖZER & Mustafa TAKAOĞLU

11-22

Mevsimplere Göre İlaç Satış Verilerinin Birliktelik Analizi İle İncelenmesi

Investigation Of Seasonal Drug Sales Data by Association Analysis

Makale Türü: Araştırma Makalesi / Paper Type: Research Paper

Emrah AYDEMİR & Mehmet YAVUZ

23-30

Yükseköğretimde Nesnelerin İnterneti İle İlişkili Uygulamalar ve Yaklaşımların İncelenmesi

Investigation Of Applications And Approaches Related To Internet Of Things in Higher Education

Makale Türü: Konferans Bildirisi / Paper Type: Conference Paper

Sevcan FAZLA & Deniz Mertkan GEZGİN

31-40

TÜRKİYE'DEKİ ORTAOKULLARIN VERİMLİLİKLERİNİN VERİ ZARFLAMA YÖNTEMİ İLE ANALİZİ

DATA ENVELOPMENT ANALYSIS FOR MEASURING THE EFFICIENCY OF SECONDARY SCHOOLS IN TURKEY

Yahya ÖZDEMİR*

Ali DEMİR**

Hasan Önal SEYHANLIOĞLU***

Öz

Eğitim konusunun ülkemizin en önemli alanlarından biri olduğunu düşünerek bu alanda Türkiye'deki şehirlerde eğitim gören ortaokul öğrencilerine yapılan yatırımların ne derece fayda sağladığını şehirler bazında görmek ve cevap arayışımız çalışmanın ortaya çıkmasında motivasyon unsuru oluşmuştur. Bu çalışmada Türkiye'deki ortaokulların verimlilikleri incelenmiştir. Verimlilikler illere göre analiz edilmiştir. Her il için o il sınırları içindeki Ortaokul düzeyindeki okul sayısı, öğrenci sayısı, şube ve derslik sayısı, kitap sayısı, kütüphane sayısı girdi değişkeni olarak kullanılmıştır. Liseye Geçiş Sistemi Merkezi Sınav puanı il ortalaması çıktı değişkenini oluşturmuştur. Veriler Veri Zarflama Analizinin CRS ve VRS modelleri kullanılarak incelenmiştir.

Anahtar Kelimeler: Veri Zarflama Analizi, VRS, CCR, Eğitim, Verimlilik.

Abstract

Considering that the subject of education is one of the most important area in our country, the question is how much Turkey's government invest in it's states for secondary school student education? And which benefits were given to them? From their education investments in those provinces has created the exit point of the study. In this study, the efficiencies of secondary school examined due to conditions of cities. The efficiencies are analyzed according to the provinces. Foreach province, the number of schools in the middle school level, number of students, branches and classes, number of books, number of libraries used as input variable. High School Transition System Center Exam Score average output variable has been created. Data is analyzed using CRS and VRS models.

Keywords: Data envelopment analysis, VRS, CCR, Training, Productivity.

* Öğr. Gör., Yalova Üniversitesi, Meslek Yüksekokulu, Bilgisayar Programcılığı Bölümü,
yahya.ozdemir56@gmail.com, ORCID: 0000-0002-0529-551X

** İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Sayısal Yöntemler Programı, alidemir2@yahoo.com,
ORCID: 0000-0001-7171-5677

*** Sakarya Üniversitesi, Sosyal Bilimler Enstitüsü, Turizm İşletmeciliği Programı, hseyhanlioglu93@gmail.com,
ORCID: 0000-0002-9056-5237

1. GİRİŞ

Kişilerin gelişim ve sosyal yeterliliklerini elde etmesine yönelik bir eylem olarak, insanın içsel dünyasını gerçekleştirmeye çalıştığı zaman zarfında, zihni, fiziki, toplumsal bir takım yetenekler, davranışlar, tutumlar ve bilgilerin kazandırılması yönündeki etkinliklerin bütününe eğitim denilmektedir (Gökçe, 2005; Özer ve Atik, 2015: 6). Başka bir tanıma göre eğitim, “Yeni yetişen kuşakların, toplumsal yaşama hazırlanırken gerekli bilgi, beceri ve kişilik kazanmalarıdır” (Şişman, 2014: 7).

Özellikle çalışmanın Türkiye üzerine yapılmış olmasından ötürü ülkenin eğitim sistemi hakkında önemli olan noktalar öne çıkarılmıştır. Türkiye'nin içinde bulunduğu ekonomik, sosyo-kültürel, demografik yapısı eğitim sistemlerinin farklı şekilde örgütlenmesine sebep olmuştur. Türkiye eğitim sistemi göz önüne alınıp incelendiği zaman merkezîyetçi bir yapı hâkimdir. Bu yapının merkezinde ise Milli Eğitim Bakanlığı bulunmaktadır. Türk Milli Eğitiminin temel ilkeleri göz önüne alındığında 1739 sayılı Milli Eğitim Temel Kanununda; genellik ve eşitlik, ferdin ve toplumun ihtiyaçlarından, eğitim hakkı, planlama, süreklilik, demokrasi eğitimi, karma eğitim, okul ile ailenin işbirliği, bilimsellik, fırsat ve imkân eşitliği vb. konulara yer verilmiş olup toplumun, bireylerin ve devletin ihtiyaçları üzerinde durup Türk toplumuna, bireyine ve devlete fayda sağlamak gözetilmiştir (Izgar, 2011: 32-33). Türk eğitim sisteminden bahsederken araştırmaya daha aydınlatıcı yön verebilmesi için sistemin belirleyicilerine değinilmiştir. Türk eğitim sisteminin belirleyicilerinin belirtilmesi ve sistemi oluşturan unsurlara yer verilmiştir. Türk eğitim sisteminin başlıca belirleyicileri arasında şunlar yer alır (Şişman, 2014: 7);

- Tevhid-i Tedrisat Kanunu,
- Milli Eğitim Temel Kanunu,
- Anayasa,
- Hükümet Programları,
- Kalkınma Planları,
- Milli Eğitim Şuraları Kararları.

Türk eğitim sisteminde eğitim kademeleri göz önünde bulundurulduğunda Okul öncesi eğitim, İlkokul Eğitimi, Ortaokul Eğitimi, Ortaöğretim ve Yükseköğretim olmak üzere sınıflandırılır. Türk eğitiminde şuan uygulanan sistem 2012-2013 yılında uygulamaya geçen 4+4+4 adlı sistemdir. Bu sistemde amacı 12 yıl kesintisiz zorunlu eğitimi sağlamaktır. Zamanla verim alınması beklenen bu sistemin içindeki öğrenci sayıları aşağıdaki tabloda belirtilmiştir.

Tablo 1: 2017-2018 Öğretim Yılı Öğrenci Sayıları

Öğretim Kademeleri	Erkek	Kız	Toplam
Okulöncesi Eğitim	782 446	718 442	1 501 088
İlkokul	2 621 732	2 482 867	5 104 599
Ortaokul	2 841 520	2 748 614	5 590 134
Ortaöğretim	2 985 179	2 704 248	5 689 427
Yükseköğretim	4 047 302	3 513 069	7 560 371

Kaynak: YÖK ve MEB' in 2017-2018 öğretim yılı istatistiklerinden derlenmiştir.

Tablo 1 'de 2017-2018 öğretim yılı öğrenci sayıları verilmiştir. Yükseköğretimde eğitim gören bireyler ön lisans, lisans, yüksek lisans ve doktora olarak yekûn olarak verilmiştir. Bu bireylerin 2 768 757 ön lisans düzeyinde, 4 241 841 lisans düzeyinde, 454 673 yüksek lisans, 95 100 doktora düzeyinde eğitim görmektedirler.

Ortaöğretim eğitimi ise 4+4 olan ilkokul ve ortaokul eğitiminden sonra yer alan dört yıllık eğitim sürecidir. Milli Eğitimin Ortaöğretim eğitimini zorunlu kılmasındaki amaçları ise eğitimi

alan bireylere asgari seviyede ortak bir genel kültür kazandırarak bu kişilere toplumun sorunlarını benimsetmek, çözüm yollarını irdeletmek ve ülkenin iktisadi, sosyal ve kültürel bağlamda kalkılmasını sağlamaktır. Bunun yanında bireyleri çeşitli program ve okullara ilgi, kabiliyetleri ölçüsünde yükseköğretime ve mesleğe hazırlamaktır. Türkiye’de Ortaöğretim kurumları üç gruba ayrılır:

- Genel ortaöğretim grubu
- Mesleki ve teknik ortaöğretim grubu
- Dini eğitimi veren ortaöğretim grubu

Burada yer alan ortaöğretim gruplarındaki öğrenci sayılarını verilmiştir. Özellikle bunun en büyük sebebi son +4 deki aktif olarak eğitim gören birey sayılarını yansıtmak amacıyla tablo haline getirilmiştir.

Tablo 2: 2017-2018 Ortaöğretim Eğitimi Alan Öğrenci Sayıları

Ortaöğretim Grubu	Erkek	Kız	Toplam
Genel ortaöğretim grubu	1 588 505	1 486 137	3 074 642
Mesleki ve teknik ortaöğretim grubu	1 117 229	870 053	1 987 282
Dini eğitimi veren ortaöğretim grubu	279 445	348 058	627 503

Kaynak: MEB’ in 2017-2018 Öğretim Yılı İstatistiklerinden derlenmiştir.

Tablo 2’de 2017-2018 ortaöğretim eğitimi alan öğrenci sayıları verilmiştir. Genel öğretim grubunu oluşturan okullar; Anadolu liseleri, Fen liseleri, Sosyal Bilimler liseleri, Güzel Sanatlar liseleri, Spor liseleri ve Özel liselerden oluşmaktadır. Mesleki ve teknik grubunu oluşturan okullar; Mesleki ve teknik liseler, Mesleki eğitim merkezleri, Çok programlı Anadolu liseleri ve Özel eğitim ve rehberlik hizmetleri sunan okullardır. Bu okulların amacı ara eleman yetiştirmek ve yükseköğretime öğrenci hazırlamaktır. Dini eğitim veren ortaöğretim grubunu oluşturan okullar; İmam-Hatip liseleri, Anadolu imam-hatip liseleri, Açık öğretim imam-hatip liseleridir. Bu okulların amacı ise imam-hatiplik, kuran kursu öğreticiliği gibi din hizmetlerinin yerine getirilmesi ile görevli olan elemanları yetiştirmek ve öğrencileri yükseköğretime hazırlamaktır.

Bu okullarda eğitim görmek için yapılan geçiş sınavının adı LGS (Liselere Giriş Sınavı)’dır. Ortaokul son sınıf öğrencileri bu sınav ile proje okulları ve Tablo 2’de yer alan grup okullarında eğitim görme hakkı kazanmaktadır. 2018’de yapılan liselere giriş sınavında her on ortaokul mezunundan sekizi bu sınava katılmıştır. Sınavda iki oturum yapılmış olup iki bölümden adaylar sınava tabi olmuşlardır. Bunlar; Sözel Bölümden 50 soru sorulmuştur (20 Türkçe, 10 T.C. İnkılap Tarihi ve Atatürkçülük, 10 Din Kültürü ve Ahlâk Bilgisi, 10 Yabancı Dil) ve sınav süresi 75 dakikadır, Sayısal Bölümden 40 soru sorulmuştur (20 Matematik, 20 Fen Bilimleri) ve sınav süresi 60 dakikadır.

Tablo 3: 2018 Yılı Liselere Giriş Sınavına katılanlara ilişkin bilgiler

Sınav Katılım Durumu	Öğrenci Sayısı
Sınav Başvuran	1 009 260
Sınav Katılan	971.657
Sınavı Geçerli	971.617
Kız	491.379
Erkek	480.238

Kaynak: MEB’in yayınladığı 2018 LGS raporundan derlenmiştir.

Tablo 3’de 2018 yılı liselere giriş sınavına katılanlara ilişkin bilgilerde de görüldüğü üzere sınava katılan bireylerin sayıları, cinsiyetleri, katılan ve sınavı geçerli olanlara dair bilgiler yer almıştır. Bu sınava katılım zorunlu olmamakla birlikte sınav sadece Milli Eğitim Bakanlığının belirlediği proje okullarına yerleşmek adına yapılmıştır.

2. VERİ ZARFLAMA ANALİZİ

Veri Zarflama Analizi (VZA), bir organizasyon ya da programın benzer özelliklere sahip birimlerin ki bu birimler sıklıkla Karar Verme Birimleri (KVB) olarak adlandırılır, doğrusal programlamaya dayanarak parametrik olmayan bir yaklaşımla performans etkinliğini ölçmek için kullanılan bir yöntemdir. KVB’nin performans etkinliği, ağırlıklı çıktıların toplamının, ağırlıklı girdilerin toplamına oranı olarak tanımlanmaktadır (Thanassoulis ve diğerleri, 2008: 264). Benzer stratejik hedeflere sahip, aynı girdilerle aynı çıktıları üreten birden fazla işletmenin karşılaştırılması bu analizin temel noktasıdır. Geleneksel verimlilik ölçümü yaklaşımlarının bazı varsayım ve kısıtlamalarına duyulan ihtiyacı ortadan kaldıran deneysel temelli bir metodolojidir. VZA, yapılan ilk çalışmalarda kar amacı gütmeyen kuruluşlar ve kamu kuruluşları için performans ölçüm aracı olarak kullanılmak üzere geliştirilmiş bir analiz olarak dikkat çekmiştir. Bununla birlikte, kar amacı gütmeyen kurumlar dışında, diğer işletme ve kuruluşlar için de zaman içinde etkin bir şekilde kullanılmaya başlanmıştır.

VZA birçok farklı kurum ve hizmet tarafından kullanılabilir. Bir kurumun birbiriyle aynı özellikleri gösteren birimlerinin performanslarını arttırmak için bu analiz çeşitli şekillerde kullanılarak etkili sonuçlar vermektedir. VZA, kullanılan tüm kaynakları ve verilen hizmetleri dikkate alarak hizmet birimlerini karşılaştırmaktadır. En verimli birimleri veya en iyi uygulama birimlerini (şubeler, bölümler, bireyler) belirlemektedir. İyileştirmelerin mümkün olduğu verimsiz birimleri belirlemektedir. Her bir birim tarafından kullanılan kaynakları diğer tüm birimlerle karşılaştırarak elde ettiği için bu analiz güçlü bir kıyaslama tekniği olarak bilinmektedir. VZA, her verimsiz birimi en verimli birimleri kadar verimli hale getirerek elde edilebilecek maliyet ve kaynak tasarrufu miktarını ve türünü hesaplama imkanını da sunmaktadır (Sherman & Zhu, 2006: 50-51).

Bu analizin en büyük avantajı, çok sayıda giriş ve çıkış değişkeni ile etkili bir şekilde gerçekleştirilebilmesidir. KVB’lerin verimlilik puanı bire eşit olduğunda (veya verimlilik değeri yüzde 100’e eşitse) verimli performansa sahiptir, aksi halde verimlilik puanı birden düşük olduğunda, KVB etkin performans göstermediği sonucuna ulaşılır (Akgöbek ve diğerleri, 2015: 46).

Etkin olmayan KVB’nin etkin üretim sınırına olan uzaklığına göre girdi yönelimli ve çıktı yönelimli VZA modelleri tanımlanmaktadır. Girdi yönelimli olan model çıktı seviyesinde değişiklik yapmadan, bu çıktı seviyesini en etkin şekilde elde etmek için girdi bileşiminde ne kadarlık bir azaltılma gerektiğini araştırmaktadır. Çıktı yönelimli model ise girdi seviyesini değiştirmeden, bu girdi seviyesi ile işletmeyi etkin hale getirebilmek için çıktı bileşiminin ne kadar artırılması gerektiğini araştırmaktadır (Matthews ve Ismail, 2006: 8).

CCR yöntemi ölçüğe göre sabit getiri varsayımına dayanmaktadır. Eğer j . karar biriminin verimliliği/etkinliği h_j ise bu durumda amaç, bu değerini maksimizasyonu olmaktadır. Bu durumda amaç fonksiyonu girdi yönelimli CCR olarak (1) formülündeki gibi ifade edilmektedir (Charnes, Cooper ve Rhodes, 1978):

$$Enbh_j = \frac{\sum_{r=1}^n u_r y_r}{\sum_{i=1}^m v_i x_i} \quad (1)$$

Kısıtlar ise (2) formülündeki gibi gösterilmektedir.

$$\begin{aligned} \frac{\sum_{r=1}^n u_r y_r}{\sum_{i=1}^m v_i x_i} &\leq 1 \\ u_r &\geq 0 \\ v_i &\geq 0 \end{aligned} \quad (2)$$

Kesirli programlama setinin çözümü doğrusal programlamaya göre daha güç olduğundan, (1) ve (2) formülleri doğrusal programlama mantığına dönüştürülerek (3) ve (4) formülleri elde edilir.

$$Enbh_j = \sum_{r=1}^n u_r y_r \quad (3)$$

$$\begin{aligned} \sum_{i=1}^m v_i x_i &= 1 \\ \sum_{r=1}^n u_r y_r - \sum_{i=1}^m v_i x_i &\geq 0 \\ u_r, v_i &\geq 0 \end{aligned} \quad (4)$$

(3) ve (4) formülleri girdi yönelimli durum için düzenlenmiştir. Eğer çıktı yönelimli CCR yöntemi kullanılacaksa bu durumda model (5) ve (6) formüllerindeki gibi olmaktadır.

$$Enkg_j = \sum_{i=1}^m v_i x_i \quad (5)$$

$$\begin{aligned} \sum_{r=1}^n u_r y_r &= 1 \\ -\sum_{r=1}^n u_r y_r + \sum_{i=1}^m v_i x_i &\geq 0 \\ u_r, v_i &\geq 0 \end{aligned} \quad (6)$$

Girdi yönelimli ve çıktı yönelimli CCR yöntemiyle karar birimlerinin etkinliğine karar vermek isteniyorsa yukarıda tanımlanan modeli bütün karar noktaları için uygulamak gerekmektedir. Kurulan bu model her bir karar noktası için çözüldüğünde her bir karar noktası için toplam etkinlik ölçütleri elde edilmektedir. Bu ölçütlerin 1'e eşit olması karar noktaları için etkinliği, 1'den küçük olmaları ise karar noktalarının etkisizliğini göstermektedir (Charnes, Cooper ve Rhodes, 1978).

BCC ya da VRS modelinin CCR modelinden farkı, ölçüğe göre değişken getiri varsayımı altında her bir karar birimi için çözülecek doğrusal program sonucu elde edilen λ (etkin olmayan bir karar noktası için etkin olası girdi çıktı bileşimi oluşturmak için gereken bilgiyi sağlayan değer) değerlerinin toplamının 1'e eşit olmasıdır. BCC yönteminin modeli (7) formülünde verilmiştir (Cooper, Seiford ve Tone, 2000: 20).

Amaç fonksiyonu,
 $Enk\Theta_k$
Kısıtlar,

$$\sum_{j=1}^N y_{rj} \lambda_{jk} \geq y_{rk} \quad \Theta_k x_{ik} - \sum_{j=1}^N x_{ij} \lambda_{jk} \geq 0 \quad \sum_{j=1}^N \lambda_j = 1 \quad (7)$$

3. YÖNTEM

Türkiye'deki ortaokulların hem başarı kalitesinin artırılması hem de verimliliklerini incelemek amacıyla bu araştırma gerçekleştirilmiştir. Türkiye'deki ortaokulların illere göre verimliliklerinin analizi için veri zarflama analizlerinden CCR modeli ve VRS modeli kullanılmıştır. Verimlilik analizinde kullanılacak değişkenlere karar verilirken Fatimah ve Mahmudah (2017) çalışmasından yararlanılmıştır. Bu çalışmada 7 adet girdi değişkeni ve 1 adet çıktı değişkeni ile birlikte 81 adet KVB bulunmaktadır. Uygulamada güvenilir sonuçlar elde edilebilmesi için, KVB sayısının, girdi ve çıktı sayısının toplamının en az üç katı olması gerektiği kuralı bu çalışmada sağlanmaktadır (Vassiloglou ve Giokas,1990). Belirlenen değişkenlere ait istatistiksel veriler toplanırken Milli Eğitim Bakanlığı 2017/18 eğitim dönemi Milli Eğitim İstatistiklerinden (MEB, 2018a), Türkiye İstatistik Kurumu'nun 2017 yılı kültür istatistikleri verilerinden (TÜİK, 2017) ve Milli Eğitim Bakanlığı 2018 yılı LGS raporundan faydalanılmıştır (MEB, 2018b). Toplanan bu veriler CCR yönteminde belirtilen formülde olduğu gibi problemin amaç fonksiyon ve kısıtları Microsoft Excel 2007 programına girilmiştir. Girilen bu veriler her bir KVB için Excel Solver yardımı ile çözülmüştür.

Bu çalışma; Türkiye'nin 81 iline ait ortaokul düzeyindeki eğitim verileri ve Liseye Geçiş Sistemi'nin Merkezi Sınav sonuçlarını kullanarak illerin verimliliklerini ölçmeyi amaçlamıştır. Bu amaç doğrultusunda kullanılan değişkenlerin bilgisi aşağıda verilmiştir.

Girdi değişkenleri:

Okul: İl genelinde Milli Eğitim Bakanlığına bağlı veya ilgili olarak eğitim öğretim faaliyetlerinin sürdürüldüğü ortaokul sayısı(2017/'18)

Şube: il genelinde ortaokulların aynı düzeydeki sınıflarının sayısı (2017/'18)

Derslik: il genelinde ortaokullarda ders yaptırılan yer/sınıf/dershane sayısı (2017/'18)

Kütüphane: il genelinde 2017 yılı kütüphane sayısı

Kitap: il genelindeki 2017 yılı kitap sayısı

Öğretmen: il genelindeki kadrolu ve sözleşmeli öğretmen sayısı (2017/'18)

Öğrenci: il genelindeki öğrenci sayısı (2017/'18)

Çıktı değişkenleri:

Sınav: Liselere Geçiş Sistemi Merkezi Sınav il ortalamaları (2018)

Tablo 4'te yukarıda ifade edilen değişkenlerin tanımlayıcı istatistik bilgileri verilmiştir.

Tablo 4: Girdi ve Çıktı Değişkenlerinin Tanımlayıcı İstatistikleri

	N	Minimum	Maximum	Ortalama	Std. Hata
Girdi					
<i>Okul</i>	81	25	1.667	231	230
<i>Şube</i>	81	192	33.823	2.768	4.196
<i>Derslik</i>	81	178	25.901	2.292	3.235
<i>Kütüphane</i>	81	2	43	14	9
<i>Kitap</i>	81	46.603	1.576.875	246.835	228.151
<i>Öğrenci</i>	81	2.905	970.031	69.014	118.571
<i>Öğretmen</i>	81	316	45.301	4.196	5.932
Çıktı					
<i>Sınav</i>	81	274	373	344	19

Tablo 5, belirlenen girdi ve çıktı değişkenlerini kullanarak 81 ilin verimlilik puanlarını göstermektedir.

Tablo 5: İllerin Girdi Yönelimli CCR Analizi Verimlilik Skorları

KVB	CCR	KVB	CCR	KVB	CCR	KVB	CCR
<i>Bartın</i>	1	<i>Erzincan</i>	0,52	<i>Eskişehir</i>	0,35	<i>Ordu</i>	0,22
<i>Bayburt</i>	1	<i>Siirt</i>	0,5	<i>Yozgat</i>	0,34	<i>Aydın</i>	0,21
<i>Kilis</i>	1	<i>Kırıkkale</i>	0,5	<i>Mardin</i>	0,34	<i>Kayseri</i>	0,2
<i>Tunceli</i>	1	<i>Uşak</i>	0,48	<i>Adıyaman</i>	0,34	<i>Denizli</i>	0,19
<i>Yalova</i>	1	<i>Batman</i>	0,48	<i>Tekirdağ</i>	0,33	<i>Balıkesir</i>	0,19
<i>Ardahan</i>	1	<i>Kırklareli</i>	0,47	<i>Giresun</i>	0,32	<i>Sivas</i>	0,19
<i>Iğdır</i>	0,79	<i>Niğde</i>	0,45	<i>Sakarya</i>	0,32	<i>Erzurum</i>	0,19
<i>Bilecik</i>	0,76	<i>Osmaniye</i>	0,44	<i>Kütahya</i>	0,31	<i>Samsun</i>	0,18
<i>Hakkari</i>	0,68	<i>Aksaray</i>	0,44	<i>Tokat</i>	0,3	<i>Hatay</i>	0,17
<i>Artvin</i>	0,67	<i>Edirne</i>	0,44	<i>Çorum</i>	0,27	<i>Mersin</i>	0,17
<i>Karabük</i>	0,66	<i>Burdur</i>	0,43	<i>Malatya</i>	0,27	<i>Manisa</i>	0,16
<i>Gümüşhane</i>	0,66	<i>Kars</i>	0,42	<i>Diyarbakır</i>	0,26	<i>Antalya</i>	0,16
<i>Şırnak</i>	0,64	<i>Zonguldak</i>	0,41	<i>Nevşehir</i>	0,26	<i>Bursa</i>	0,15
<i>Karaman</i>	0,61	<i>Bitlis</i>	0,4	<i>Trabzon</i>	0,26	<i>Adana</i>	0,14
<i>Sinop</i>	0,6	<i>Elazığ</i>	0,4	<i>Kahramanmaraş</i>	0,25	<i>İzmir</i>	0,11
<i>Düzce</i>	0,58	<i>Çanakkale</i>	0,39	<i>Muğla</i>	0,24	<i>Konya</i>	0,1
<i>Kırşehir</i>	0,56	<i>Van</i>	0,38	<i>Kocaeli</i>	0,24	<i>Ankara</i>	0,07
<i>Bingöl</i>	0,54	<i>Rize</i>	0,38	<i>Isparta</i>	0,24	<i>İstanbul</i>	0,05
<i>Çankırı</i>	0,54	<i>Ağrı</i>	0,37	<i>Şanlıurfa</i>	0,24		
<i>Bolu</i>	0,53	<i>Muş</i>	0,36	<i>Afyon</i>	0,23		
<i>Amasya</i>	0,52	<i>Kastamonu</i>	0,36	<i>Gaziantep</i>	0,22		

Genel Etkinlik Ortalaması: 0.40

Tablo 5’da verilen girdi yönelimli CCR analizi verimlilik skorları sonucuna göre; 6 il etkin performans göstermekte iken 75 il kaynaklarını etkin olarak kullanmamaktadır. Performans

etkinliği % 50'den az olan 57 il analiz sonucunda tespit edilmiştir. Verimlilik puanı en düşük olan il %5 ile İstanbul olmuştur. Bartın, Bayburt, Kilis, Tunceli, Yalova, Ardahan illeri %100 etkin iller olarak tespit edilmiştir. Etkin performans gösteren iller tüm illerin yaklaşık %7,5'dir.

Tablo 6: İllerin Girdi Yönelimli VRS Analizi Verimlilik Skorları

KVB	VRS	KVB	VRS	KVB	VRS	KVB	VRS
Ardahan	1	Sinop	0,61	Kastamonu	0,44	Muğla	0,24
Bartın	1	Düzce	0,58	Zonguldak	0,42	Afyon	0,23
Bayburt	1	Nevşehir	0,57	Bitlis	0,41	Gaziantep	0,22
Karabük	1	Bingöl	0,55	Kütahya	0,39	Ordu	0,22
Kilis	1	Siirt	0,55	Ağrı	0,39	Kayseri	0,22
Trabzon	1	Denizli	0,55	Van	0,39	Sivas	0,21
Tunceli	1	Çankırı	0,54	Muş	0,38	Antalya	0,21
Uşak	1	Bolu	0,54	Eskişehir	0,36	Samsun	0,19
Yalova	1	Isparta	0,53	Mardin	0,35	Erzurum	0,19
Iğdır	0,87	Adıyaman	0,53	Yozgat	0,35	Hatay	0,18
Kırşehir	0,85	Kırıkkale	0,52	Tokat	0,34	Mersin	0,17
Hakkari	0,84	Erzincan	0,52	Çorum	0,34	Manisa	0,16
Bilecik	0,77	Elazığ	0,51	Sakarya	0,33	Bursa	0,15
Şırnak	0,72	Malatya	0,49	Tekirdağ	0,33	Adana	0,15
Artvin	0,72	Batman	0,49	Giresun	0,33	İzmir	0,12
Gümüşhane	0,68	Kırklareli	0,48	Balıkesir	0,27	Konya	0,1
Burdur	0,66	Çanakkale	0,47	Diyarbakır	0,27	Ankara	0,07
Niğde	0,63	Aksaray	0,46	Aydın	0,26	İstanbul	0,06
Amasya	0,62	Edirne	0,44	Kahramanmaraş	0,26		
Karaman	0,62	Kars	0,44	Şanlıurfa	0,25		
Osmaniye	0,61	Rize	0,44	Kocaeli	0,24		

Genel Etkinlik Ortalaması: 0.47

Yapılan VRS(BCC) analizi sonucunda 9 ilin etkin performans gösterdiği görülmüştür. Etkin performans gösteren iller tüm illerin yaklaşık %11'ini oluşturmaktadır. Etkin performans gösteren iller Ardahan, Bartın, Bayburt, Karabük, Kilis, Trabzon, Tunceli, Uşak, Yalova illeri olmuştur (Tablo 6). Hem VRS hem CCR yöntemlerinin her ikisinde de en düşük performans etkinliği skoruna sahip il İstanbul ili olmuştur.

4. SONUÇ

Bu çalışma, Türkiye'deki ortaokulların etkinlik ölçümlerini Veri Zarflama Analizinden Ölçeğe göre sabit getiri (CCR) ve ölçeğe göre değişken getiri (BCC) modeli yaklaşımlarını kullanarak literatürde ilk defa araştırmaktadır. Burada Veri Zarflama Analizi yöntemini uygulayarak yedi girdi ve bir çıktı ile Türkiye'deki 81 il için hem CCR hem de VRS modellerine göre etkinlik puanını hesaplanmıştır. Parametrik olmayan doğrusal programlamaya dayanan Karar Verme Birimlerinin etkinliğini ölçmek için en popüler yöntemdir. Analiz sonuçlarına göre; VZA'nin VRS modeli, Türkiye'deki ortaokulların performanslarını ölçmek için CCR modelinden daha iyi verimlilik puanı sağlamıştır. CCR modelinde etkin performans gösteren iller tüm illerin yaklaşık %7.5'i iken VRS modelinde bu oran %11 düzeyindedir. Analiz sonucunda; etkin performans gösteren iller Ardahan,

Bartın, Bayburt, Karabük, Kilis, Trabzon, Tunceli, Uşak, Yalova illeri olmuştur. Sonuç olarak Ortaokulların başarı kalitesini daha da yükseltmek için çok daha düzenli aralıklarla veri zarflama analizlerinin yapılması çok faydalı olacaktır. Böylelikle Ortaöğretim kurumlarındaki öğrenciler başarılı eğitim ve öğretim yılı yaşamaları bakımından yararlı olacaktır. Ortaya konan bu önemli çalışma hem kapsam alanı genişletilerek hem de Ülkemizdeki tüm Ortaokulların değerlendirilmesinde farklı değişken parametrelerinin de çalışmaya sokulması çok başarılı bir model olması açısından önem arz edecektir.

KAYNAKÇA

- Abbott, M., ve Doucouliagos, C. (2003). The Efficiency Of Australian Universities: A Data Envelopment Analysis. *Economics Of Education Review*, 22(1), 89-97.
- Akgöbek, Ö., Nişancı, İ., Kaya, S., ve Eren, T. (2015). Veri Zarflama Analizi Yaklaşımını Kullanarak Bir Eğitim Kurumunun Şubelerinin Performanslarını Ölçme. *Sosyal Bilimler Araştırma Dergisi*, 4(3), 43-54.
- Bal, V. (2013). Vakıf Üniversitelerinde Veri Zarflama Analizi İle Etkinlik Belirlenmesi. *Manas Sosyal Araştırmalar Dergisi*, 2(1), 1-20.
- Banker, R. D., Charnes, A., ve Cooper, W. W. (1984). Some Models For Estimating Technical And Scale in efficiencies in Data Envelopment Analysis. *Management Science*, 30(9), 1078-1092.
- Baysal, A. G. M. E., ve Toklu, B. (2001). Veri Zarflama Analizi İle Bazı Orta Öğretim Kurumlarının Performanslarının Değerlendirilmesi. *Süleyman Demirel Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Dergisi*, 2-6.
- Charnes, A., Cooper, W. W., ve Rhodes, E. (1978). Measuring The Efficiency Of Decision Making Units. *European Journal Of Operational Research*, 2(6), 429-444.
- Cooper, W. W., Seiford, L. M., ve Tone, K. (2000). Data Envelopment Analysis. *Handbook On Data Envelopment Analysis*, 1st Ed.; Cooper, WW, Seiford, LM, Zhu, J., Eds, 1-40.
- Demir, E., ve Durakoğlu, M. (2013). Çorum İlindeki Liselerin 2012-2013 Eğitim Öğretim Sürecindeki Etkinliğinin Veri Zarflama Analizi İle Ölçülmesi. *Hitit Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 6(1), 19-42.
- Fatimah, S., ve Mahmudah, U. (2017). Two-Stage Data Envelopment Analysis (DEA) For Measuring The Efficiency Of Elementary Schools in Indonesia. *International Journal of Environmental And Science Education*, 12(8), 1971-1987.
- Flegg, A. T., Allen, D. O., Field, K., ve Thurlow, T. W. (2004). Measuring The Efficiency Of British Universities: A Multi-Period Data Envelopment Analysis. *Education Economics*, 12(3), 231-249.
- Gökçe, F. (2005). *Devlet ve Eğitim*. Ankara: Tek Ağaç Yayınevi.
- İzgar, H. (2011). "Eğitim Bilimine Giriş", Musa Gürsel Ve Muhsin Hesapçıoğlu (Edt.), *Türk Eğitim Siteminin Genel Yapısı*, Konya: Eğitim Kitapevi.
- Johnes, J. (2006). Data Envelopment Analysis And its Application to the Measurement of Efficiency in Higher Education. *Economics Of Education Review*, 25(3), 273-288.
- Johnes, J., ve Li, Y. U. (2008). Measuring The Research Performance Of Chinese Higher Education Institutions Using Data Envelopment Analysis. *China Economic Review*, 19(4), 679-696.
- M. Vassiloglou, D. Giokas, (1990). A Study Of The Relative Efficiency of Bank Branches: An Application Of Data Envelopment Analysis. *Journal Of Operational Research Society*, 41, 7, 591-597.
- Matthews K., Ismail M., (2006). Efficiency And Productivity Growth Of Domestic And Foreign Commercial Banks in Malaysia, *Cardiff Economics Working Papers*, Cardiff, U.K., S.8.
- Milli Eğitim Bakanlığı (2018a). *Milli Eğitim İstatistikleri, Örgün Eğitim 2017/18*. T.C. Millî Eğitim Bakanlığı Strateji Geliştirme Başkanlığı.

- Milli Eğitim Bakanlığı (2018b). Liselere Geçiş Sistemi (LGS) Merkezi Sınavla Yerleşen Öğrencilerin Performansı. Eğitim Analiz ve Değerlendirme Raporları Serisi.
- Özden, Ü. (2008). Veri Zarflama Analizi (VZA) İle Türkiye'deki Vakıf Üniversitelerinin Etkinliğinin Ölçülmesi. İstanbul Üniversitesi İşletme Fakültesi Dergisi, 37(2), 167-185.
- Özer, N. ve Atik, S. (2015). "Eğitim Bilimine Giriş", Celal Tayyar Uğurlu (Edt.), Eğitimin Temel Kavramları, Ankara: Eğiten Kitap Yayınları.
- Sherman, H. D., ve Zhu, J. (2006). Data Envelopment Analysis Explained. Service Productivity Management: Improving Service Performance Using Data Envelopment Analysis (DEA), 49-89.
- Şişman, M. (2014). Eğitim Bilimine Giriş. Ankara: Pegem Akademi.
- Thanassoulis, E., Portela, M. C., Despic, O. (2008). Data Envelopment Analysis: The Mathematical Programming Approach To Efficiency Analysis. The Measurement Of Productive Efficiency And Productivity Growth, 251-420.

SALDIRI TESPİT SİSTEMLERİNE MAKİNE ÖĞRENME ETKİSİ

THE EFFECT OF MACHINE LEARNING ON INTRUSION DETECTION SYSTEMS

Çağdaş ÖZER*

Mustafa TAKAOĞLU**

Öz

Teknoloji ilerledikçe ve insanlar ile makineler arasındaki bağlantı arttıkça, sistem ve veri güvenliği daha önemli hale gelmektedir. Saldırganlar, sistemleri inceleyerek açıklarını bulmaya çalışmakta ve kimi zaman da başarıya ulaşmaktadırlar. Başarıya ulaşan saldırılar maddi manevi zararlara yol açmaktadır. Bunların önüne geçebilmek için anti virüs veya güvenlik duvarları kullanılmaktadır. Anti virüs ve güvenlik duvarları uzman saldırılarına karşı her zaman etkin bir savunma sağlayamayabilirler. Bu ve benzer sorunlardan yola çıkılarak saldırı tespit sistemleri geliştirilmeye çalışılmıştır. Bunu, çeşitli sistemlerden ve ağ kaynaklarından bilgi toplayarak ve sonra olası güvenlik sorunları için bilgileri analiz ederek gerçekleştirirler. Çalışmamızda bu sorunlara odaklanılmış ve makine öğrenmesi tekniklerini, bilinen saldırı çeşitlerini ve sunucu tabanlı saldırı yöntemlerinin verilerini kullanarak saldırı tespit sistemi eğitmek amaçlanmıştır. Bu doğrultuda çalışmamızda, CesarFTP, WebDAV, Icecast, Tomcat, OS SMB, OS Print Spool, PMWiki, Wireless Karma, PDF N, Backdoored Executable, Browser Attack, Infectious Media saldırı verileri birleştirilerek veri seti oluşturulmuştur. Ortaya çıkan bu veri seti ise Destek Vektör Makinesi (DVM) ve Naive Bayes (NB) kullanılarak sınıflandırılmış ve eğitilmiştir ve elde edilen sonuçlar paylaşılmıştır. DVM ile sistemin eğitilmesi ve test edilmesinden sonra 0,7129 başarı oranına, ardından tekrar uygulanan boyut azaltma ve Temel Bileşen Analizi sonrasında Naive Bayes ile birlikte 0,7914 başarı seviyesine ulaşılmıştır. Bu da bahsi geçen saldırı verileri kullanılarak eğitilen saldırı tespit sistemi aktif ve çalışıyor konumda iken, gelen saldırıları %79 oranında doğru tespit edebildiğini göstermiştir.

Anahtar Kelimeler: Saldırı Tespit Sistemleri, Makine Öğrenmesi, Destek Vektör Makinesi, Naif Bayes.

Abstract

As technology advances and the link between people and machines grows, system and data security become more important. Attackers try to find gaps by examining systems and sometimes succeed. Successful attacks lead to material and moral damages. Anti-virus or firewalls are used to prevent them. Anti-virus and firewalls may not always provide an effective defense against expert attackers. Based on these and similar problems, intrusion detection systems have been developed. They do this by collecting information from various systems and network resources and then analyzing the data for possible security issues. This study focuses on these problems and aims to train an intrusion detection system using machine learning techniques, known attack types, and data from server-based attack methods. In this direction, the data set was created by combining CesarFTP, WebDAV, Icecast, Tomcat, OS SMB, OS Print Spool, PMWiki, Wireless Karma, PDF N, Backdoored Executable, Browser Attack, Infectious Media attack data. The resulting data set was classified and trained using the Support Vector Machine (DVM) and Naive Bayes (NB), and the results were shared. Following the training and testing of the system with DVM, the success rate of 0.7129 was achieved, followed by the re-applied size reduction and Principal Component Analysis with Naive Bayes and the success level of 0.7914. This showed that the intrusion detection system, which was trained using the aforementioned intrusion data, was able to detect 79 percent of incoming attacks accurately while it was active and operational.

Keywords: Intrusion Detection Systems, Machine Learning, Support Vector Machine, Naive Bayes.


* Arş. Gör. İstanbul Aydın Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, cagdasozer@aydin.edu.tr, ORCID: 0000-0002-0581-7955

** Arş. Gör. İstanbul Aydın Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, mustafatakaoglu@aydin.edu.tr, ORCID: 0000-0002-1634-2705

1. GİRİŞ

Bilgi sistemleri ve ağlar elektronik saldırılara maruz kalabilirler. Bilgi güvenliğini ihlal etme girişimleri her gün, internette yaygın olarak bulunan güvenlik açığı değerlendirme araçlarının yanı sıra ticari olarak da kullanılabilen bu araçların kullanılabilirliği ile birlikte artmaktadır (Urmila ve Balasubramanian, 2019). SubSeven, Nmap, L0ftCrack, BackOrifice gibi araçların tümü sistemleri taramak, tanımlamak, araştırmak ve delmek için kullanılabilir. Ağları korumak için güvenlik duvarları ve çeşitli anti virüsler kullanılır. Peki, bunlar ne kadar yeterlidir? Güvenlik duvarları sizleri dışarıdan gelen saldırılara karşı çok iyi koruyabilir ama eğer sisteminizin içinde bir açık var ise uyarma olasılığı bulunmaz.”Script Kiddie” diye tabir edilen kişiler, interneti sürekli olarak alt ağlar tarafından yapılan taramalar dâhil, bilinen hatalara karşı tarar. Bazı zamanlarda ise, tamamen yasal yollarla rakip bir firma, rekabet avantajı elde etmek için personeller istihdam eder ve oluşturdukları bu ekiple sisteminize sızmaya çalışırlar. Saldırı tespit sistemlerinin önemi belirttiğimiz bu sebepten ötürü daha iyi anlaşılmaya başlamıştır. Söz konusu sistemlerin kullanımının bilgi teknolojilerinde %60’dan fazla olduğu 2012 yılında yapılan bir ankette belirtilmiştir (Richardson, 2011). Aktif bir çalışma konusu olmasına ve üzerinde çok sayıda insanın araştırma ve geliştirme yapmasına rağmen, bu tarz saldırıları etkin bir şekilde tespit edebilecek, standartları belirlenmiş bir sistem henüz geliştirilememiştir (Breitenbacher vd., 2019).

Araştırma toplulukları, sistem saldırılarına karşı istatistik tabanlı, imza tabanlı, davranış tabanlı ve karma tabanlı teknikler kullanarak savunmaya çalışmışlardır (Kraur ve Singh, 2014). Bu tekniklerin her birinin öncelikli hedefi, sistem istismarının gerçek zamanlı veya mümkün olduğunca gerçek zamana yakın olarak tanımlamak ve saldırının neden olduğu hasarı ortadan kaldırmak veya en aza indirmek için belli başlı saldırıları karantina altına almaktır (Kraur ve Singh, 2014). Şekil 1’de, 2018 yılında siber saldırıların daha çok hangi dosya biçimlerini kullandığı gösterilmiştir (cp<r>, 2018).

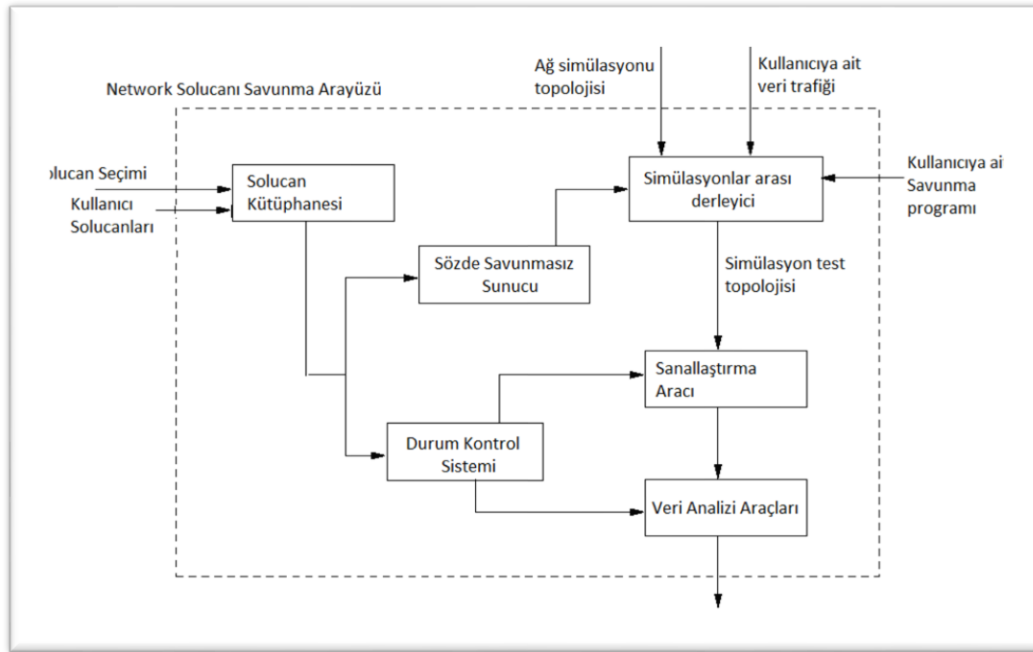


Şekil 1. Kötü Amaçlı Dosya Türleri Dağılımı (cp<r>, 2018).

Çalışmamızın amacı, var olan sunucu tabanlı saldırı çeşitleri ve bunların verilerini kullanarak saldırı tespit sistemini eğitmek, bu şekilde sistemi yeni gelebilecek saldırılara karşı korumaya çalışmaktır. Sistemin her an her çeşit saldırıya karşı koymasına hem bellek yönetimi hem de güç tüketimi açısından akıllıca olmayacaktır dolayısıyla gelen saldırının doğru ve etkin bir şekilde sınıflandırılması gerekmektedir. Bu fikirden yola çıkılarak sınıflandırma algoritmaları kullanılmıştır. Saldırının doğru tahmininden sonra bu saldırıya yönelik bir savunma sisteminin devreye girmesi, sistemi amacına ulaştırarak ve minimum hasar ile saldırıyı atlatmayı sağlayacaktır.

2. LİTERATÜR TARAMASI

Saldırı profillerinin statik doğasından ötürü, algılama teknikleri ortamdaki zamana bağlı değişikliklere uyum sağlayamamaktadır (Aygün, 2017). Saldırı ve saldırı araçları, büyük hacimli ağ trafiği verileri, dinamik ve karmaşık davranışlar ve yeni tür saldırılarla daha karmaşık hale gelmiştir (Idhameda vd., 2018). Veri modelindeki herhangi bir değişiklik için sistem sürekli eğitim ile güncellenmiş bir profile ihtiyaç duymaktadır (Aygün, 2017). Yeni gözlemleri (yeni saldırılar) değerlendirmek için limiti (veya saptama parametrelerini) ayarlamak, tespitin kalitesi üzerinde önemli bir etkiye sahip olduğu için istatistiksel bir algılama yaklaşımı tasarlamada kritik bir adımdır (Yıldırım, 2014). Eğer eşik değeri çok dar ise, sık sık yanlış pozitif alarmlarla sonuçlanacak şekilde aşılır ve çok geniş olursa da limit asla aşılmayacak ve birçok yanlış negatif alarm ortaya çıkacaktır (Yıldırım, 2014). Zaman zaman, algılama parametreleri yeni saldırıları tespit etmek için elle çıkarılır veya ayarlanır. Tüm bu faktörler, çevrimdışı modunda çalışmak için istatistiksel algılama yaklaşımlarını sınırlar. Ve böylece, gerçek zamanda anlık algılama ve koruma için kullanılamazlar.



Şekil 2. Polimorfik Solucanlara Karşı Örnek Savunma (Cheetancheri, 2007).

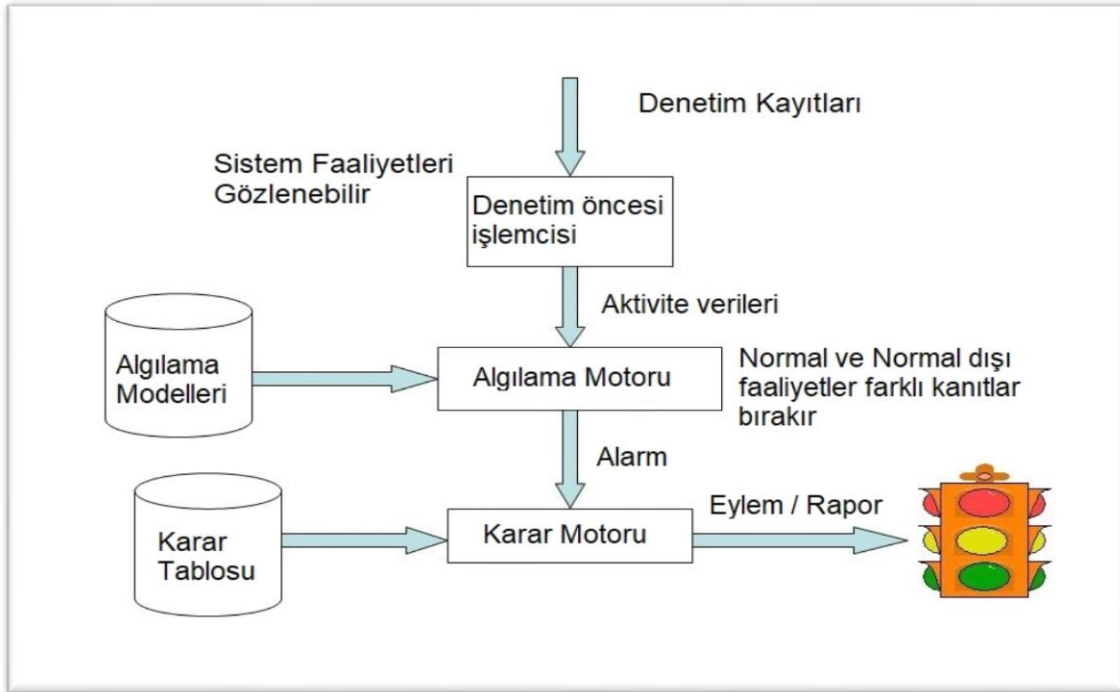
İmza temelli tespit teknikleri, esas olarak polimorfik solucanlara odaklanmaktadır. Şekil 2’de bilinen solucan türlerine karşı sistemi test etmeye dair örnek bir şekil gösterilmiştir. Bu uygulamanın sebebi ise saldırı tespit sistemlerinin tasarlanmasında, genellikle yaşanmış saldırıların felaket senaryolarının temel alınmasıdır (Çepçin, 2018). Bu saldırıların karakteristik özelliklerini incelemeyen, yeni gelebilecek saldırılara karşı bir sistem tasarlanması oldukça zor olacaktır. Günlük hayatta kullandığımız anti virüs programları bile, hangi tür olduğundan bağımsız, yüklü olduğu cihazı savunmak için imzalarla ihtiyaç duyar (Rozenblum, 2001). Üç tür imza vardır. Bunlar; içerik tabanlı, semantik tabanlı ve güvenlik açığı tabanlı imzalardır. İçerik tabanlı imzalar, bir solucan uygulamasına özgü özellikleri yakalar bu nedenle yeterince genel olmayabilir ve diğer istismarlar tarafından kaçırılabilir. Semantik tabanlı imzalar, alt dizelere dayalı yaklaşımlarla karşılaştırıldığında, hesaplama açısından pahalıdır. Dahası, Snort gibi mevcut STS’lerde (Saldırı Tespit Sistemi) uygulanamazlar. Güvenlik açığı tabanlı imzalar, solucanın yararlandığı ve üretilmesi zor olan güvenlik açığının özelliklerini yakalar.

Ağ anormallik tespitinde uygun bir çözüm sağlamak için normallik kavramına ihtiyaç duyulur. Normal düşüncesi, genellikle sistem dinamiklerinde yer alan temel değişkenler arasındaki

ilişkileri ifade eden resmi bir model tarafından ortaya konulur. Normallik modeli tarafından belirtilen sistemin profiline veya davranışına göre sapma derecesi yeterince yüksekse, bir olay veya nesne anormal olarak tespit edilir (Yıldırım, 2014). Örneğin, denetimli bir yaklaşım kullanan bir anormallik tespit sistemi S alalım. Bir $S = (M, D)$ çifti olarak düşünülebilir; burada M, sistemin normal davranış modelidir ve D, bir etkinlik kaydı verildiğinde, bir sapma derecesine sahip olan bir yaklaşım ölçüsüdür (Yıldırım, 2014). Faaliyetler M modeline göre yapılmıştır. Böylece, her sistem esas olarak iki modüle sahiptir:

- Modelleme Modülü
- Algılama Modülü.

Modelleme Modülü; normallik modelini (M) elde etmek için sistemleri eğitir. Elde edilen model daha sonra yeni olay veya nesnelere veya anormal veya aykırı olarak trafiği değerlendirmek için algılama modülü tarafından kullanılır (Yıldırım, 2014). Olayların veya nesnelere anormal veya aykırı olarak sınıflandırılmasına izin veren sapmanın ölçümüdür. Özellikle, modelleme modülü, dinamik senaryolarla başa çıkmak için uyarlamalı olmalıdır (Yıldırım, 2014).



Şekil 3. Saldırı Tespit Sistemi Bileşenleri (Intrusion Detection/Prevention Systems, 2016).

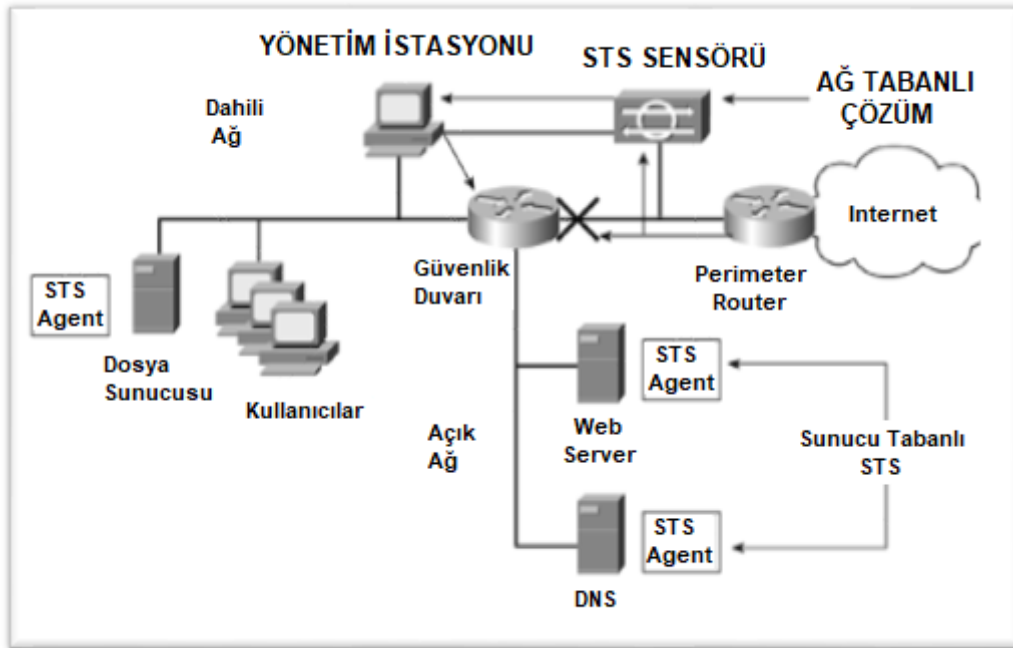
Saldırı tespit sistemleri insan yaşamının önemli bir parçası haline gelmektedir (Jabbar, Aluvalub, Reddy, (2017). İzinsiz giriş, bilgisayar ve ağ bileşenlerinin güvenliğini gizlilik, bütünlük ve kullanılabilirlik açısından tehlikeye atmayı amaçlayan bir dizi eylemdir (Aygün, 2017). Güvenlik mekanizmasının yetkisiz bir şekilde girişini ve kontrolünü sağlamak için içeriden veya dışarıdan bir saldırgan tarafından yapılabilir. Ağ sistemlerinin altyapısını korumak için, saldırı tespit sistemleri (STS'ler), olası bir güvenlik ihlalini tespit etmek için bir ev sahibi veya bir ağdaki çeşitli alanlardaki bilgileri toplayan ve analiz eden sağlam mekanizmalar sağlar (Staniford-Chen, Cheung, Crawford, Dilger, Frank, Hoagland, Levitt, Wee, Yip, Zerkle, 1999). Bir saldırı tespit sistemi iki temel fonksiyondan oluşur. Bunlar: şüphelilere ilişkin denetim verilerini toplamak ve denetim verilerini analiz etmektir (Wu, Song, Lin, Aurelle, Liu, Ding, Song, Moon (2018). Şekil 3'te, herhangi bir saldırı tespit sisteminin varsayılan olarak sahip olması gereken bileşenler gösterilmiştir.

İzinsiz giriş algılama işlevleri:

- Kullanıcı, sistem ve ağ etkinliklerini izleme ve analiz etme

- Olası güvenlik açıkları raporlarının oluşturulması için sistemleri yapılandırma
- Sistemi ve dosya bütünlüğünü değerlendirme
- Tipik saldırıların kalıplarını tanıma
- Anormal aktiviteyi analiz etme
- Kullanıcı politikası ihlallerini izleme

STS, ana makinenin veya ağın güvenliğini değerlendirmek için güvenlik açığı değerlendirmesini kullanır (cp<r>, 2018). Saldırı tespiti, hırsızlık faaliyetlerinin normal sistem aktivitelerinden belirgin şekilde farklı olduğu ve dolayısıyla saptanabilir olduğu varsayımı üzerine çalışır (Staniford-Chen, vd, 1999). STS'ler, gerçek zamanlı çalışmasına yakınlığına göre iki sınıfa ayrılabilir. Bunlardan ilki "Ana Bilgisayar Tabanlı Saldırı Tespit Sistemi", ABTSTS'dir. İkinci sınıf ise Ağ Tabanlı Saldırı Tespit Sistemi, ATSTS olarak adlandırılır (Kraur ve Singh, 2014).



Şekil 4. Sunucu Tabanlı STS ("IDS Introduction",2008).

Sunucu tabanlı STS, harici ara yüzler yerine bilgisayar sisteminin iç yapısını izler ve analiz eder. Sunucu tabanlı STS hangi programın hangi kaynaklara eriştiği ve gayri meşru erişim girişiminde bulunduğu gibi iç faaliyetleri tespit edebilir (Bilge ve Dumitras, 2012). Benzer şekilde, bir sistemin durumunu ve depolanan bilgilerini, RAM veya dosya sistemindeki günlük dosyalarında veya başka bir yerde olup olmadığına bakabilir (Bilge ve Dumitras, 2012). Şekil 4'te sunucu tabanlı STS mekanizmasına dair örnek gösterilmiştir. Sunucu tabanlı STS, iç veya dış herhangi bir şeyin, işletim sisteminin yürürlüğe koyduğu güvenlik politikasını engelleyip engellemediğini izleyen bir aracı olarak düşünülebilir (Kraur ve Singh, 2014).

Ağ tabanlı STS; Ağ verilerindeki istenmeyen ve kötü niyetli izinsiz girişleri tespit etmeye yarar (Shenfield, Day ve Ayes, 2018). Müdahaleler tipik olarak anormal şablonlar olarak ortaya çıkar ancak belirli teknikler verileri sıralı olarak modellemekte ve anormal alt dizileri tespit etmektedir (cp<r>, 2018). Bu anormalliklerin başlıca nedeni, bilgi çalmak ya da ağı bozmak için ağa yetkisiz erişim sağlamak isteyen dış saldırganların başlattığı saldırılardır. Tipik bir ortamda, bir ağ dünyanın geri kalanına internet üzerinden bağlanır (Kraur ve Singh, 2014). Network tabanlı STS, tüm gelen paketleri veya akışları okur, şüpheli kalıpları bulmaya çalışır. Örneğin, çok sayıda farklı bağlantı noktasında çok sayıda "Geçiş kontrol protokolü" bağlantı isteği çok kısa bir sürede gözlenirse, ağdaki bazı bilgisayarlarda bir kişinin bir "bağlantı noktası taraması" yaptığını

varsayabiliriz. Port taramaları çoğunlukla, gelen shell kodlarını, sıradan bir saldırı tespit sisteminin yaptığı şekilde algılamaya çalışır (cp<r>, 2018). Gelen trafiği teftiş etmenin yanı sıra, bir Network tabanlı STS de giden veya yerel trafikten izinsiz giriş hakkında değerli bilgiler sağlar (Staniford-Chen, vd, 1999). Algılama mekanizmasına göre üç tip olarak sınıflandırılabilir. Bunlar suüstimal tabanlı, anomali tabanlı ve bunların birleşimi olan karışık ataklardır (Kraur ve Singh, 2014).

Sistemler ve uygulamalar, güvenliğin asla önemli bir sorun olmadığı bir ortamda çalışmayı hedeflemiştir (Bilge ve Dumitras, 2012). Bununla birlikte, mevcut ağ senaryosunda kullanıldığında aynı sistemler ve uygulamalar, büyük güvenlik sorunlarından biri haline gelir. Örneğin, bir sistem izole edildiğinde mükemmel bir şekilde güvenli olabilir, ancak Internet'e bağlı olduğunda savunmasız hale gelir (Kraur ve Singh, 2014). Saldırı tespiti, bu sistemlere karşı saldırıların tanımlanmasını ve böylece saldırılara yanıt vermesini sağlar (Staniford-Chen, vd, 1999). İkincisi, bilgi güvenliği ve yazılım mühendisliği uygulamalarının kısıtlamaları nedeniyle, bilgisayar sistemleri ve uygulamalarında, bir saldırgan tarafından sistemlere veya uygulamalara saldırmak için kullanılacak tasarım kusurları veya hataları olabilir (Bilge ve Dumitras, 2012).

İzinsiz giriş tespiti konusunda birçok çalışma yapılmıştır ve sınıflandırma ve kümeleme gibi çoklu makine öğrenme algoritmalarından veya bunları bir özellik seçimi yaklaşımı ile birlikte farklı fikirlerle birleştirerek kullanılmıştır (Mazini, 2018). Sistemlerde belirli önlemler alındığı zaman riskler en aza indirilebilir. Sistem veya ağ üzerindeki şüpheli girişler, hesaplara gereğinden fazla başarısız yanlış girişler, neden açıldığı belli olmayan kullanıcı hesapları, açıklanamayan yeni dosyalar, bilinmeyen dosya isimleri, özellikle sistem dosyalarında dosya adlarına ve/veya tarihlerinde değişiklikler, ağ üzerindeki beklenmeyen trafik artışları, kullanıcı hesaplarındaki anormal hareketler (yetkinin olmadığı yerlere ısrarlı girmeye çalışmalar), sistem üzerindeki yetki noktalarına ve önemli noktalarına erişim istekleri gözlemlenerek bu tür saldırılar gerçek zamanlı veya gerçek zamanlıya oldukça yakın bir zaman diliminde bulunabilir ve engellenebilir.

Son olarak bilgi sistemleri kaynakları üzerindeki saldırgan etki setinin, heterojen bir parametrik ortamdaki değerler arasında birçok anomaliye yol açtığı not edilmelidir (Zhumangaliyeva vd., 2019).

3. YÖNTEM VE UYGULAMA

3.1. Veri

Çalışmamızda kullanılacak veri seti; CesarFTP, WebDAV, Icecast, Tomcat, OS SMB, OS Print Spool, PMWiki, Wireless Karma, PDF N, Backdoored Executable, Browser Attack, Infectious Media saldırı verileri birleştirilerek oluşturulmuştur. Ortaya çıkan bu veri seti ise Destek Vektör Makinesi (DVM) ve Naive Bayes (NB) kullanılarak sınıflandırılmış ve eğitilmiştir.

3.2. Yöntem

Öncelikle kullanılacak veri setlerimiz Düşük Varyans Filtresi, Yüksek Korelasyon Filtresi ve Temel Bileşen Analizi yöntemlerine tabi tutulduktan sonra eğitime hazır bir hale getirilmiştir. Kullanılan yöntemler aşağıda açıklanmıştır.

3.2.1. Düşük Varyans Filtresi: Veri setinde küçük değişiklikler olan veri sütunları çok az bilgi taşır. Böylece, belirli bir eşikten daha düşük varyansa sahip tüm veri sütunları kaldırılır. Dikkatli olunması gereken nokta ise varyans aralığına bağlıdır; bu nedenle, bu tekniği uygulamadan önce normalizasyon uygulanması gereklidir.

3.2.2. Yüksek Korelasyon Filtresi: Çok benzer eğilimlere sahip veri sütunlarının da çok benzer bilgiler taşıması olasıdır. Bu durumda, yalnızca biri makine öğrenme modelini beslemek için yeterli olacaktır. Burada nümerik sütunlar arasında ve sırasıyla Pearson'un Ürün Moment Katsayısı ve

Pearson chi kare değeri olarak nominal sütunlar arasındaki korelasyon katsayısı hesaplanır. Korelasyon katsayısı eşikten daha yüksek olan sütun çiftleri yalnızca bir taneye düşürülür. Korelasyon ölçeğe duyarlı olduğundan, anlamlı bir korelasyon karşılaştırması için sütun normalizasyonu gereklidir.

3.2.3. Temel Bileşen Analizi (TBA) : Bir veri setinin orijinal n koordinatlarını ortogonal olarak asıl bileşenler adı verilen yeni bir n koordinat grubuna dönüştüren istatistiksel bir prosedürdür. Dönüşümün bir sonucu olarak, ilk ana bileşen olası en büyük varyansa sahiptir; müteakip her bileşen, önceki bileşenlerle ortogonal olduğu (yani onlarla korelasyon olmayan) kısıtlama altında mümkün olan en yüksek varyansa sahiptir. Yalnızca ilk $m < n$ bileşeninin tutulması, veri bilgisinin çoğunu, yani verideki değişimi korurken veri boyutsallığını azaltır. TBA dönüşümünün orijinal değişkenlerin göreceli ölçeklendirilmesine duyarlı olduğuna dikkat edilmesi gerekir. TBA uygulanmadan önce veri sütunu aralıklarının normalleştirilmesi gerekir.

3.2.4. Destek Vektör Makinesi (DVM) : Destek vektörleri, hiper düzlemine daha yakın olan ve hiper düzlemin konumunu ve yönünü etkileyen veri noktalarıdır. Bu destek vektörlerini kullanarak, sınıflandırıcının marjını maksimize ederiz. Destek vektörlerini silmek, hiper düzlemin konumunu değiştirir. Lojistik regresyonda, lineer fonksiyonun çıktısı alınmıştır ve değeri sigmoid fonksiyonunu kullanarak $[0,1]$ aralığında yayılmıştır. Eğer yayılan değer bir eşik değerden (0.5) büyükse, ona etiket 1, yoksa etiket 0 atanmıştır. DVM'de doğrusal fonksiyonun çıktısı alınmıştır ve bu çıktı 1'den büyükse, bir sınıfla ve eğer çıktı -1 ise, başka bir sınıfta olduğu tespit edilmiştir. DVM'de eşik değerleri 1 ve -1 olarak değiştirildiğinden, marjini etkileyen bu takviye değerleri aralığı $[-1,1]$ olarak elde edilmiştir. Gerekli özellikler çıkarılmış ve eğitim ve test verilerine ayrılmıştır. Verilerin %90'ı eğitim için, geri kalan %10'u test için kullanılmıştır. Python dili, Numpy kitaplığı kullanılarak DVM modeli oluşturulmuştur. epochs = 1 ve alpha = 0.0001 kullanılarak ilerlenmiştir. Kullanılan kütüphaneler ve DVM standart tanımlamalarından bir örnek, Şekil 5'te gösterilmiştir.

```
import numpy as np
from numpy import linalg
import cvxopt
import cvxopt.solvers

def linear_kernel(x1, x2):
    return np.dot(x1, x2)

def polynomial_kernel(x, y, p=3):
    return (1 + np.dot(x, y)) * p

def gaussian_kernel(x, y, sigma=5.0):
    return np.exp(-linalg.norm(x-y)**2 / (2 * (sigma ** 2)))
```

Şekil 5. Kullanılan Python Kütüphaneleri ve DVM tanımlamaları (Blondel, 2019).

Oluşturduğumuz veri seti, doğrusal olmayan bir yapıya sahip olduğu için bu yapıya sahip bir fonksiyon ile test edilmiştir. Kullanılan fonksiyon, Şekil 6'da gösterilmiştir.

```
def test_non_linear():  
    X1, y1, X2, y2 = gen_non_lin_separable_data()  
    X_train, y_train = split_train(X1, y1, X2, y2)  
    X_test, y_test = split_test(X1, y1, X2, y2)  
  
    clf = SVM(gaussian_kernel)  
    clf.fit(X_train, y_train)  
  
    y_predict = clf.predict(X_test)  
    correct = np.sum(y_predict == y_test)  
    print "%d out of %d predictions correct" % (correct, len(y_predict))  
  
    plot_contour(X_train[y_train==1], X_train[y_train==-1], clf)
```

Şekil 6. Doğrusal Olmayan Veriler için Test Fonksiyonu (Blondel, 2019).

3.2.5. Naif Bayes: Naif Bayes modeli, eğitim veri setindeki verilerin bir özetinden oluşur. Bu özet daha sonra tahminlerde bulunurken kullanılır. Toplanan eğitim verilerinin özeti, her özneliğin sınıf değerine göre ortalamasını ve standart sapmasını içerir. Örneğin, iki sınıf değeri ve 7 sayısal özellik varsa, o zaman her bir özellik (7) ve sınıf değeri (2) kombinasyonu için ortalama ve standart bir sapmaya yani 14 özellik özetine ihtiyaç vardır. Bunlar, her bir sınıf değerine ait belirli özellik değerlerinin olasılığını hesaplamak için tahminlerde bulunurken gereklidir. Bu özet verilerin hazırlanması şu alt görevlere ayrılabilir: Verileri sınıflara göre ayırma, hesap ile ortalama, standart sapmayı hesaplama, veri kümesini özetleme ve sınıflara göre öznelikleri özetleme.

Ardından eğitim verilerinden hazırlanan özetler kullanılarak tahminler yapılabilir. Öngörüler yapmak, verilen bir veri örneğinin her sınıfa ait olma olasılığını hesaplamayı ve ardından tahmin olarak en büyük olasılık olan sınıfı seçmeyi içerir. Bu şu şekilde ayrılabilir: Gauss olasılık yoğunluğu fonksiyonunun hesaplama, sınıf olasılıklarını hesaplama, tahmin yapma ve doğruluk tahmini hesaplama. Son olarak, test veri setindeki her veri örneği için tahminler yaparak modelin doğruluğu tahmin edilebilir. GetPredictions() bu tahmini yapar ve her test örneği için bir tahmin listesi döndürür. Tahminler, test veri setindeki sınıf değerleri ile karşılaştırılabilir ve bir sınıflandırma doğruluğu, %0 ve %100 arasında bir doğruluk oranı olarak hesaplanabilir. GetAccuracy() bu doğruluk oranını hesaplar. Naif Bayes algoritmasının kullanılan fonksiyonlardan birkaçı, Şekil 7’de gösterilmiştir.


```
#Separate by Class
def separateByClass(dataset):
    separated = {}
    for i in range(len(dataset)):
        vector = dataset[i]
        if (vector[-1] not in separated):
            separated[vector[-1]] = []
            separated[vector[-1]].append(vector)
    return separated

#Test separating by class
"""
dataset = [[1,20,1],[2,21,0],[3,22,1]]
separated = separateByClass(dataset)
print('Separated instances: {0}'.format(separated))
"""

#Calculate Mean
def mean(numbers):
    return sum(numbers)/float(len(numbers))

def stdev(numbers):
    avg = mean(numbers)
    variance = sum([pow(x-avg,2) for x in numbers])/float(len(numbers)-1)
    return math.sqrt(variance)

#Test stdev & mean calculation
"""
numbers = [1,2,3,4,5]
print('Summary of {0}: mean={1}, stdev={2}'.format(numbers, mean(numbers), stdev(numbers)))
"""
```

Şekil 7. Naive Bayes Örnek Fonksiyonları (Askaruly, 2019).

DVM algoritmasının seçilmesinin sebebi: DVM'nin net bir ayrılma marjı ile gerçekten iyi çalışması, yüksek boyutlu alanlarda etkili olması, boyut sayısının örnek sayısından daha büyük olduğu durumlarda etkili olması, karar işlevinde de (destek vektörleri denir) bir eğitim noktaları alt kümesi kullanması, bu nedenle de belleği etkin bir şekilde kullanmasıdır. Naif Bayes algoritmasının tercih edilme sebebi ise, destek vektör makinesi ile birlikte kullanıldığında nasıl bir sonuç vereceğini izlemek ve daha iyi bir sınıflandırma yapabiliyor mu onu test etmektir.

4. BULGULAR

Çalışmamızda oluşturduğumuz veri kümemize ilk olarak Destek Vektör Makinesi algoritması uygulanmış, 6013 tane veri içerisinde 4287 tanesi doğru tahmin edilirken 1726 tanesi yanlış tahmin edilmiştir. Başarı oranı ≈ 0.71 olmuştur. Elde edilen sonuçlar ayrıca Tablo 1'de paylaşılmıştır.

Tablo 1. DVM Algoritması Başarı Oranı

Başarı Oranı
accuracy = accuracy_score(y_test, result)
Sonuç : 0,712938192283729182
print(accuracy)

Başarı oranını arttırmak için ikinci bir sınıflandırma algoritması kullanılmak istenmiştir. Var olan veri setimiz boyut azaltma ve temel bileşen analizine tekrar tabi tutulmuştur ve ardından eğitim süresini azaltmak amacıyla veri setimizde benzer eğilime sahip test verileri ayrılmıştır. Bu işlemler sonrasında Naive Bayes algoritması uygulanmıştır. Özetlemek gerekirse, Naive Bayes bütün koşullu olasılıkların çarpımı olarak düşünülebilir. Elde edilen sonuç Tablo 2’de paylaşılmıştır.

Tablo 2. Naive Bayes Algoritması Başarı Sonucu

Başarı Oranı
predictions = getPredictions(summaries, testSet)
accuracy = getAccuracy(testSet, predictions)
Sonuç : 0,791428501394022834

Naive Bayes algoritmasının uygulanmasından sonra elde edilen sonucu incelediğimizde, başarı oranı $\approx 0,79$ olmuştur. Naif Bayes algoritmasının hızlı çalışan istekli bir sınıflandırma algoritması olması, gerçek zamana yaklaşabilmesi ve aynı zamanda çok sınıflı tahmin özelliği için iyi çalışması özelliği ile tercih sebebi olmuştur. Zira çalışmamızda hem savunma sistemleri hem de kullandığımız veri seti olsun, çok sınıf bulunmaktadır.

5.SONUÇ

Zarara sebebiyet verebilecek saldırılara karşı koymak için kullanılacak sistemler ve bu sistemi izleyen insanların gözünden kaçabilecek şeyler olduğu da düşünüldüğünde, risk faktörünü en aza indirgeyecek olan şey bu kontrolleri makineye bırakmaktır. Bunun olması için sistemlere felaket senaryoları düzenlenmeli, daha önceden yapılmış olan saldırılara karşı dayanıklı olup olmadığı test edilmeli, yazılan yazımların güvenlik faktörleri de düşünülerek doğru bir şekilde planlanmaları ve ona göre geliştirilmeleri gerekmektedir. Makine öğrenmesi yöntemleri kullanılarak devamlı olarak izlenmesi gereken sistemler otomatik hale getirilebilir ama bu sistem kesinlikle güvenli çalışıyor demek değildir. Zira daha önceden kullanılmamış bir yöntem bulan saldırgan(lar) bir sistem açığından faydalanıp zarara sebebiyet verebilir. Sistemler bu yüzden devamlı olarak geliştirilmeli, güncel teknoloji haberleri de takip edilip kullanılan sistemler de güncellenmelidir.

DVM sınıflandırıcılar, Naive Bayes algoritmasına kıyasla daha iyi doğruluk ve daha hızlı tahmin oranlarıyla çalışırlar. Karar aşamasında daha az hafıza kullanılır çünkü bir alt eğitim noktası kullanılmaktadır. DVM net bir ayrılma marjı ve yüksek boyutlu boşluk ile iyi çalışır. DVM, fazla eğitim süresi nedeniyle büyük veri kümeleri için uygun değildir. Ayrıca eğitimlerde Naive Bayes ile karşılaştırıldığında daha fazla zaman almaktadır. Örtüşen sınıflarla zayıf çalışır ve kullanılan çekirdek türüne de duyarlıdır.

Çalışmamız için gerçekleştirdiğimiz uygulamada, DVM algoritması; düşük varyans filtresi, yüksek ilgileşim filtresi ve temel bileşen analizi yöntemleri ile temizlediğimiz veri setlerimizle kullanılmıştır. Elde edilen veriler Naif Bayes yöntemine tabi tutulmuştur. DVM ile sistemin eğitilmesi ve test edilmesinden sonra 0,712938192283729182 başarı oranına ulaşılmış, ardından

tekrar uygulanan boyut azaltma ve TBA sonrasında Naif Bayes kullanılarak 0,791428501394022834 yani %79'luk başarı seviyesine ulaşılmıştır. Elde edilen %79'luk başarı seviyesi, saldırı tespit sistemleri için yüksek bir başarı oranıdır.

Başarı oranını ilerletmek için hassasiyet ve modellerin tekrar gözden geçirilmesi gerekir. Algoritmanın iyi veya kötü çalışması, tamamıyla verinin büyüklüğü, kalitesi ve niteliğine, kullanılabilir hesaplama süresine, görevin aciliyetine ve verilerle ne yapmak istendiğine bağlıdır. Bu yüzden herhangi bir algoritma için diğerlerine göre daha “iyidir” diye kesin bir söylemde bulunmak doğru olmaz.

Ayrıca anlaşılması gereken bir durum ise, saldırı tespit sistemlerinin savunma yapmaya tek başlarına yeterli olmadıklarıdır. Bu sistemlerin trafiği devamlı olarak izlenir ve sonuçları bir yöneticiye rapor edilir. Tespit edilen bir istismarın sistemi ele geçirmesini önlemek için otomatik olarak işlem yapılamaz. Saldırganlar, ağa girdikten sonra güvenlik açıklarından çok hızlı bir şekilde yararlanabilir ve bu sistemlerin müdahalesini sınırlandırabilirler.

Çalışmamızda paylaştığımız sonuç, makine öğrenmesi yöntemleriyle eğitilen saldırı tespit sistemlerinin hem içeriden hem de dışarıdan gelebilecek benzer saldırılara karşı yüksek başarı oranıyla yakalayabildiğini göstermektedir. Bu tip sistemlerin geliştirilmesindeki en büyük sorun, paylaşılmayan verilerdir. Sıfıncı gün saldırıları gibi şirketlerin paylaşmaya yanaşmadığı kritik veriler, eğitim aşamasında kullanılmadığı için sistem bu tarz saldırılara karşı yanıt vermeye yetersiz kalmaktadır. Eğitim ve test aşamaları için daha fazla veri bulunması, başarı sonucunu mutlak suretle arttıracaktır.

Son olarak bu alanda yapılabilecek başlıca çalışmalar; hibrit saldırı tespit sistemlerinin geliştirilmesidir. Yeni geliştirilen saldırı tekniklerinin takip edilmesi ve önerilecek hibrit sistemlerde kullanılması, ayrıca en önemli sorunlardan biri olan saldırı verilerinin temin edilmesi ve verilerin kullanılabilir hale getirilmesinde yapılabilecek çalışmalara ihtiyaç bulunmaktadır.

KAYNAKÇA

- Askaruly S. (2019). Naive Bayes From Scratch in Python Erişim Tarihi: <https://gist.github.com/tuttelikz/94f750ef3bf14f8a126a>. Rozenblum D. (2001). Understanding Intrusion Detection Systems. The SANS Institute Information Security Reading Room.
- Aygün R. C. (2017). Derin Öğrenme Yöntemleri ile Bilgisayar Ağlarında Güvenliğe Yönelik Anormallik Tespiti. İstanbul, 2016-04-01-YL01, s.27. Erişim adresi: <https://docplayer.biz.tr/64409341-Derin-ogrenme-yontemleri-ile-bilgisayar-aglarinda-guvenlige-yonelik-anormallik-tespiti-r-can-aygun-danisman-doc-dr-a.html>
- Bilge K., Dumitras T. (2012). An Empirical Study of Zero-Day Attacks In The Real World. CCS'12, October 16–18 Raleigh, North Carolina, USA. Copyright 2012 ACM 978-1-4503-1651-4/12/10.
- Blondel M. (2019) Support Vector Machines Erişim adresi: <https://gist.github.com/mblondel/586753/f740949d0336484567dd422fe53445ac8821f5b2>
- Breitenbacher D., Homoliak I., Aung Y. L., Tippenhauer N. O., and Elovici Y. (2019). HADES-IoT: A Practical Host Based Anomaly Detection System for IoT Devices. In ACM Asia Conference on Computer and Communications Security (AsiaCCS '19), July 9–12, 2019, Auckland, New Zealand. ACM, New York, NY, USA, 6 pages. <https://doi.org/10.1145/3321705.3329847>
- Cheetancheri G. S. (2007). Collaborative defense against zero-day and polymorphic worms: detection, response and an evaluation framework. Submitted in partial satisfaction of the

- requirements for the degree of Doctor of Philosophy in Computer Science in the Office of Graduate Studies of the University of California Davis.
- Cp<r>, (2018). Check Point Cyber Attack Trends: Mid-Year Report 2018, Check Point Research Software Technologies.
- Idhammada M., Afdela K., Belouchb M. (2018). Distributed Intrusion Detection System for Cloud Environments based on Data Mining techniques. ScienceDirect. Procedia Computer Science 127 (2018) 35–41.
- IDS Introduction (2008). Erişim adresi: <http://etutorials.org/Networking/Router+firewall+security/Part+VII+Detecting+and+Preventing+Attacks/Chapter+16.+Intrusion-Detection+System/IDS+Introduction/>
- Intrusion Detection/Prevention Systems (2016). Objectives and Deliverable Understand the concept of IDS/IPS and the two major categorizations: by features/models. Erişim adresi: <https://slideplayer.com/slide/4982018/>
- Jabbar M. A., Aluvalub R., Reddy S. S. S. (2017). RFAODE: A Novel Ensemble Intrusion Detection System. ScienceDirect. Procedia Computer Science 115 (2017) 226–234.
- Kraur R., Singh M. (2014). Efficient Hybrid Technique for Detecting Zero-Day Polymorphic Worms (978-1-4799-2572-8/14/\$31.00_c IEEE).
- Mazini, M., et al. (2018). Anomaly network-based intrusion detection system using a reliable hybrid artificial bee colony and AdaBoost algorithms. Journal of King Saud University – Computer and Information Sciences (2018), <https://doi.org/10.1016/j.jksuci.2018.03.011>
- Richardson R. (2011). Computer Crime and Security Survey. Computer Security Institute, CSI. Tech. report, p.25, figure 15.
- Shenfield A., Day D., Ayesh A. (2018). Intelligent intrusion detection systems using artificial neural networks. ScienceDirect. ICT Express Volume 4, Issue 2, June 2018, Pages 95-99.
- Staniford-Chen S., Cheung S., Crawford R., Dilger M., Frank J., Hoagland J., Levitt K., Wee C., Yip R., Zerkle D. (1999). Graph Based Intrusion Detection System For Large Networks. Department of Computer Science, University of California at Davis, CA 95616.
- Urmila T. S. ve Balasubramanian R. (2019). Dynamic Multi-layered Intrusion Identification and Recognition using Artificial Intelligence Framework. International Journal of Computer Science and Information Security (IJCSIS), Vol. 17, No. 2, February 2019, ISSN 1947-5500
- Wu M., Song J., Lin L. W. L., Aurelle N., Liu Y., Ding B., Song Z., Moon Y. B. (2018). Establishment of intrusion detection testbed for CyberManufacturing systems. ScienceDirect. Procedia Manufacturing 26 (2018) 1053–1064.
- Yıldırım M. Z. (2014). Makine Öğrenmesi Yöntemleri ile Network Üzerinde Saldırı Tespiti. Yüksek Lisans Tezi, Karabük Üniversitesi, 902-1-014, s.5.
- Zhumangaliyeva N., Korchenko A., Doszhanova A., Shaikhanova A., Gulmira S., Smagulov S. ve Erzhan S. (2019). Detection Environment Formation Method for Anomaly Detection Systems, International Journal of Mechanical Engineering and Technology, 10(3), 2019, pp. 220-235. <http://www.iaeme.com/IJMET/issues.asp?JType=IJMET&VType=10&IType=3>

MEVSİMLERE GÖRE İLAÇ SATIŞ VERİLERİNİN BİRLİKTELİK ANALİZİ İLE İNCELENMESİ

INVESTIGATION OF SEASONAL DRUG SALES DATA BY ASSOCIATION ANALYSIS

Emrah AYDEMİR*

Mehmet YAVUZ**

Öz

Dijital ortamlarda saklanması kolaylaştıkça artan veri kayıtları tek başına değersizdir. Belirli bir amaç doğrultusunda işlenip anlamlı bir hale dönüştürülmesi sonucu ortaya çıkan veri madenciliği çeşitli alanlara uygulanmaktadır. Finans, pazarlama, sigortacılık, bankacılık, elektronik ticaret, iletişim, borsa, sanayi, bilim ve mühendislik, risk analizi, eğitim ve sağlık bu alanlardan bir kısmı olmakla birlikte özellikle sağlık alanındaki uygulamalarının faydalarının sayısız olduğu söylenebilir. Bu çalışmada Türkiye’de yer alan bir eczanenin bir yıllık ilaç satış verileri düzenlenmiş ve birliktelik analizi ile incelenmiştir. Mevsimlere göre yapılan analizler sonucu en çok birlikte satılan ilaçların belirlenmesi amaçlanmıştır. Çalışma sonuçları eczanenin bulunduğu yer, sağlık kuruluşlarına yakınlık, zaman ve salgın hastalık gibi birçok etkenden etkilenmektedir. Çalışma sonucunda bölgedeki hastalıklar hakkında fikir sahibi olunmakla birlikte eczaneler için ihtiyaç duyulan ilaçlar hakkında da fikir verecektir. Yapılacak ileriki çalışmalarda farklı bölgelerdeki eczane verilerinin yine farklı zamanlardaki verileri ile ayrı ayrı değerlendirilerek sonuçların karşılaştırılması yararlı olacaktır.

Anahtar Kelimeler: Veri madenciliği, Birliktelik analizi, İlaç, Reçete.

Abstract

As data storage is easier to store in digital environments, data recordings alone are worthless. Data mining, which is the result of being processed and turned into meaningful for a specific purpose, is applied to various fields. Finance, marketing, insurance, banking, electronic commerce, communication, stock exchange, industry, science and engineering, risk analysis, education and health are some of these areas, but it can be said that the benefits of applications in the field of health are numerous. In this study, an annual drug sales data of a pharmacy located in Turkey regulated and examined by association analysis. As a result of seasonal analyzes, it is aimed to determine the most commonly sold drugs. The results of the study are affected by many factors such as the location of the pharmacy, proximity to health institutions, time and epidemic. At the end of the study, it will give an idea about the diseases in the region and will give an idea about the drugs needed for pharmacies. In the future studies, it will be useful to evaluate the pharmacy data in different regions with the data at different times and compare the results separately.

Keywords: Data mining, Association analysis, Drug, Prescription.

* Kırşehir Ahi Evran Üniversitesi, Mühendislik-Mimarlık Fakültesi, emrah.aydemir@ahievran.edu.tr,
ORCID:0000-0002-8380-7891

** Milli Eğitim Bakanlığı, yavuz.mehmet21@gmail.com, ORCID:0000-0001-6218-232X

1. GİRİŞ

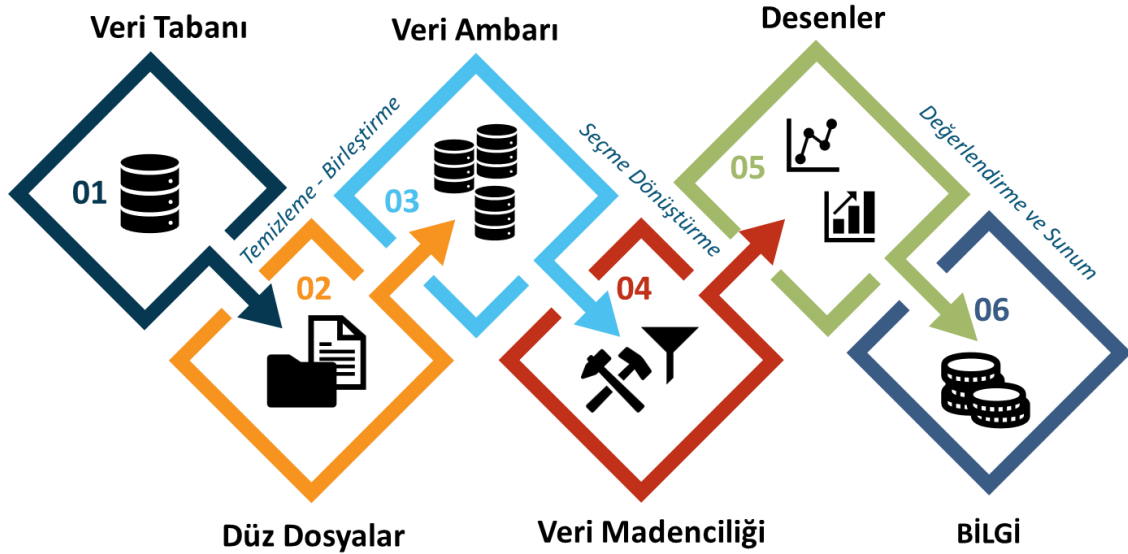
Teknolojilerin gelişmesi, veri depolama yapılarının yaygınlaşması ve internet erişiminin artması çok çeşitli verilerin kaydedilmesini ve bu verilerin dijital ortamlarda saklanmasını kolaylaştırmış ve ucuz hale getirmiştir. Ancak bu şekilde üretilen ve depolanan ham veriler tek başlarına değersizdir. Bunlar belli bir amaç doğrultusunda işlenmesiyle bir anlam ifade etmeye başlar (Kalikov, 2006). Bu sebeple günümüzde büyük miktarlardaki verileri işleyip kullanılabilir hale getiren yöntemler büyük önem kazanmaya başlamıştır. Bu ham veriyi çeşitli yöntemlerle işleyerek bilgiye veya anlamlı veriye dönüştürme işlemleri veri madenciliği ile yapılabilmektedir (Özbay, 2015).

Veri madenciliği kavramı alinyazında birçok kişi tarafından farklı tanımlanmaktadır. Veri yığınları arasında gizli kalmış, bir takım analizler yoluyla geçerli ve işe yarar bilgi elde edilmesi (Aydemir, 2018), saklanan verilerden matematiksel ve istatistiksel yöntemler yardımı ile anlamlı bilgilerin keşfedebilmesi (Altıntaş, 2010), verilerin analiz edilmesi ve gizli ifadelerin otomatik veya yarı otomatik araçların yardımı ile bulunması (Tang ve MacLennan 2005) ve geniş gözlemleri veri setlerindeki şüphe edilmeyen ilişkileri analiz etme ve yeni yollarla veri sahiplerine anlamlı ve kullanışlı bir şekilde özetleme yöntemi şeklinde tanımlanabilir (Hand vd., 2001).

Veri madenciliği günümüzde birçok farklı alanda başarılı bir şekilde kullanılmaktadır. Bu alanlardan bazıları finans, pazarlama, sigortacılık, bankacılık, elektronik ticaret, iletişim, borsa, sanayi, bilim ve mühendislik, risk analizi, eğitim ve sağlık (Albayrak, 2017; Bramer, 2007). Başarılı bir şekilde uygulanan bu alanlardan özellikle sağlık, günümüzün en önemli bilimsel araştırma birimlerinden olduğu için bu alandaki bilgi sistemleri de araştırmalar için çok büyük veri kaynaklarıdır (Yıldırım vd., 2008). Bu alandaki çalışmalar ilaçların geliştirilmesi, ilaç etkilerinin tespit edilmesi, hasta test sonuçlarının tahmin edilmesi, hastalıkların önceden teşhis ve tedavi edilmesinde önemli bir yere sahiptir. Bu çalışmada da sağlık sektörünün bir kolu olan eczane ve ilaçlar ile ilgili uygulama yapılmıştır.

Etkili bir veri madenciliği uygulaması için farklı türdeki verileri ele almak, veri madenciliği algoritmasının etkinliği ve ölçeklenebilirliği, sonuçların yararlılığı, kesinlik ve anlamlılık kriterlerini sağlaması, keşfedilen kuralların farklı formatlarda gösterimi, farklı ortamlarda yer alan verilerle işlem yapabilme, gizlilik ve veri güvenliği özellikleri gibi şartların sağlanması gerekir. Ayrıca veri madenciliği bilgi keşfi sürecinin bir parçası şeklinde yürütülmektedir. Bilgi keşfi sürecinin aşamaları ise aşağıdaki gibidir (Denier vd., 2009).

1. Verileri temizleme (Gereksiz verileri çıkarmak)
2. Verileri bütünleştirme (Farklı tipteki veri kaynaklarını birleştirmek)
3. Verileri seçme (Analiz ile ilgili verilerin seçilmesi)
4. Verilerin dönüşümü (Verinin veri madenciliğinde kullanılabilir şekle dönüştürülmesi)
5. Veri madenciliği (Veri örüntüleri yakalayabilmek için akıllı metotlar uygulamak)
6. Desenleri değerlendirme (Ölçümlerden elde edilmiş bilgiyi temsil eden farklı desenleri tanımlama)
7. Bilgi sunumu (Elde edilen bilginin kullanıcıya sunulması) (Han ve Kammer, 2001; Delen vd., 2005).



Şekil 1. Bilginin keşfi süreci (Han ve Kamber, 2006).

Literatürdeki sağlık alanında veri madenciliğinin kullanılmasına yönelik çalışmalar incelendiğinde birçok farklı çalışmanın varlığına rastlanmıştır. Bunların bazıları; sağlık sigortacılığında eczane-ilaç firması arasında ilişkilendirmenin yapıldığı çalışma (Akpınar ve Kasapbaşı, 2019), tıbbi veri madenciliği üzerine yapılan çalışmaların anlatıldığı ve Hacettepe Üniversitesi Hastanelerinde yapılacak bir veri madenciliği ile ilgili kısa bilginin verildiği çalışma (Yıldırım vd., 2008), veri madenciliği metotlarının ülkemiz sağlık sektöründe nasıl kullanıldığına ve hangi alanlarda kullanılabileceğine yönelik çalışma (Terzi, 2019), yapay sinir ağları teknikleri ile tıbbi teşhislerin etkisinin incelendiği çalışma (Wasan vd., 2006) ve son olarak tıpta uygulanabilecek veri madenciliği teknikleri ve özellikleri için daha uygun olmalarını sağlayan mekanizmalar dâhil olmak üzere bazı makine öğrenme tekniklerinin sunulduğu çalışma (Lavrač, 1999) şeklinde sıralanabilir. Fakat çalışmamızın inceleme alanı olan eczaneler hakkında yapılmış çalışma oldukça sınırlıdır. Eczanelerin sattıkları ilaçlardan hangi dönemlerde hangi ilaçların birlikte satıldığını bilmesi ve varsa olağan dışı bir durum buna karşı fazla ilaç tedarik etmek gibi önlem alması açısından önemlidir. Bu da çalışmanın önemini artırmaktadır.

2. YÖNTEM

Veri madenciliği yöntemleri kullandıkları verinin yapısına ve keşfedebildikleri örüntü biçimlerine göre kategorilere ayrılmıştır. Birçok kaynak veri madenciliği teknikleri için farklı kategoriler yapmış olmakla birlikte bunlardan en yaygın olarak kabul göreni J. Han'ın öne sürdüğü aşağıdaki kategorilerdir (Ertuğrul vd., 2013).

- Tanımlama ve Ayrımlama (Characterization and Discrimination),
- Birliktelik Analizi (Association Analysis)
- Sınıflandırma ve Öngörü (Classification and Prediction),
- Kümeleme Analizi (Cluster Analysis),
- Sıradışılık (istisna) Analizi (Outlier Analysis),
- Evrimsel Analiz (Evolution Analysis).

Yukarıdaki analizlerden, elde edilen kurallar ile nesne veya nesne grupları arasındaki ilişkiler tanımlanabilir. Böylece alınacak kararlar ve yapılacak tanımlamalarda yol gösterici olarak kullanılabilir. Buradaki çalışmada ise birliktelik analizi ilaç satış verilerine uygulanmıştır.

2.1. BİRLİKTELİK ANALİZİ

Birliktelik analizi birbiriyle ilişkili olan değişkenlerin ortaya çıkarılması ve aralarındaki bağlantının büyüklüğünün belirlenmesi şeklinde ifade edilmektedir (Erdem ve Özdağoğlu, 2008). Önceki verilerin içerisinde birlikte kullanılan davranışların tespit edilerek ortaya çıkarılması yöntemleridir. Bu durumun tespit edilmesinde verilerin birden fazla satırda yer alması gerekmektedir (Oğuzlar, 2004).

Hesaplama mantığından dolayı hızlı sonuç vermesi ile çok büyük veri setlerine kolaylıkla uygulanabilmesi Birliktelik Kuralı Analizini ticari amaçlı veri tabanlarının veri madenciliğinde gittikçe yaygınlaşan bir araç haline getirmiştir. Birliktelik kuralındaki amaç; alışveriş esnasında müşterilerin satın aldıkları ürünler arasındaki birliktelik ilişkisini bulmak, bu ilişki verisi doğrultusunda müşterilerin satın alma alışkanlıklarını tespit etmektir. Satıcılar, keşfedilen bu birliktelik bağıntıları ve alışkanlıklar sayesinde etkili ve kazançlı pazarlama ve satış imkanına sahip olmaktadır (Koyuncuğil ve Özgülbaş, 2009).


Birliktelik analizinde birçok farklı algoritma kullanılmaktadır. Bunlar; AIS algoritması, SETM algoritması, Apriori algoritması, AprioriTID algoritması, FP-Growth algoritması şeklinde sıralanabilir. Yapılacak çalışmada birliktelik kurallarının belirlenmesinde en çok tercih edilen ve gelişmiş uygulamalarda kullanılan “Apriori” algoritması kullanılmıştır. Bu algoritması hem sıralı algoritmalar arasında uygulandığı veri büyüklüğüne göre daha iyi performans sergilemesi, hem de paralel algoritmaların temelini oluşturması sebebiyle tercih edilmiştir. Bu algoritmadaki özellikler ile veriler, boolean ilişki kuralları ile değerlendirilir (Cao vd., 2016).

Apriori algoritması Destek (Support) ve Güven (Confidence) parametrelerini dikkate alarak çalışmaktadır. Destek ve Güven parametreleri ne kadar büyükse birliktelik kurallarının da o kadar güçlü olduğunu ifade eder. Apriori algoritmasının varsayılan Destek değeri %10 ve Güven değeri ise %80’dir. Eğer parametre değeri verilmemiş ise bu değerler ile kurallar oluşturulmaktadır (Uslu, 2018). Destek ve güven değerleri aşağıdaki gibi formüle edilmiştir (Bilen vd., 2012).

- **Destek (Support) Değeri:** Bir ilişkinin tüm alışverişler içinde hangi oranda tekrarlandığını belirtir. Destek $(A \rightarrow B) = A$ ve B ’yi birlikte içeren işlemlerin sayısı / Toplam işlem sayısı
- **Güven (Confidence) Değeri:** X ürününü alan müşterilerin Y ürününü alma olasılığını ortaya belirtir Güven $(A \rightarrow B) = A$ ve B ’yi birlikte içeren işlemlerin sayısı/ A ’yı içeren tüm işlemlerin sayısı

2.2. VERİLERİN ANALİZİ

07.05.2018 ile 29.04.2019 tarihleri arasındaki toplam 357 gün için ilaç satış verileri elde edilmiştir. Tarih, İşlem Numarası, İlaç Adı ve Satış Adedi şeklinde elde edilen veriler öncelikle veritabanına yüklenerek düzenlenmiştir. İlaç adlarında her ilacın iç farklılıklarını barındıran metinlerin yer aldığı görülmüştür. Öncelikle bu ilaçların tekil olması sağlanmış ve iç ayrıntıları silinmiştir. Böylelikle 1379 tekil ilacın kaldığı görülmüştür. Ardından bu ilaç adlarının sütunlarda ve satırlarda her bir ilaca yönelik satışın olup olmadığını gösterecek şekilde bir düzenleme yapılmıştır. 3758 adet satışın ise yalnızca bir ilaç ile gerçekleştiği görülünce bunlar veriler arasından çıkartılmış ve geriye 16143 adet satış verisi kalmıştır. Birliktelik analizi için Weka programı kullanılmıştır. Weka programı soru işareti (?) değerlerini yokluk olarak kabul etmektedir. Varlık değeri olarak ise yalnızca t değerinin girilmesi ile sağlanmıştır. Böylece 268X1379 boyutlarında bir matris elde edilmiştir. Aşağıda verilerin arff uzantılı dosyadaki görüntüsünden bir kısmı verilmiştir.



Şekil 2. Arff uzantılı dosyadaki verilerden örnek bir görünüm

3. BULGULAR

Weka programı aracılığıyla Apriori algoritması verilere uygulanmıştır. Başarı ölçütü olarak Confidence değeri seçilmiş ve en düşük güven ölçütü (minMetric) 0.5 olarak belirlenmiştir. İlaç satışlarına yönelik yapılan analizde öncelikle verilerin mevsimlere göre ayrıştırılması sağlanmıştır. Dört mevsime göre ayrıştırılan veriler ayrı ayrı analiz edilmiştir. Mevsimlere göre veri sayıları aşağıdaki Tablo 1'deki gibidir.

Tablo 1. Mevsimlere Göre Veri Sayıları

Mevsim	Veri Sayısı
İlkbahar	3304
Yaz	4472
Sonbahar	5208
Kış	6917

Sonbahar mevsimi için yapılan birliktelik analizi sonucunda en çok satılan 10 ilaç birlikteliği aşağıdaki gibidir. Birlikte satılan ilaçların satış sayıları ve güven katsayısı (conf) yanında gösterilmiştir.

1. ASIST, CORTAIR (156) ==> VENTOLIN (150) conf:0.96
2. CORTAIR, PEDIFEN (154) ==> VENTOLIN (147) conf:0.95
3. AUGMENTINBID, CORTAIR (153) ==> VENTOLIN (141) conf:0.92
4. CORTAIR, IBURAMIN (150) ==> VENTOLIN (135) conf:0.9
5. FLUREND, PENOS (148) ==> AFERIN (130) conf:0.88
6. BEPANTHEN (147) ==> EVIN (128) conf:0.87
7. CALPOL, CORTAIR (145) ==> VENTOLIN (125) conf:0.86
8. ASIST, CORTAIR, PEDIFEN (140) ==> VENTOLIN (121) conf:0.86
9. AFERIN, CYCLADOL (138) ==> PENOS (115) conf:0.83
10. AUGMENTIN, CORTAIR (131) ==> VENTOLIN (105) conf:0.8

İlkbahar mevsimi için ise yapılan birliktelik analizi sonucunda en çok birlikte satılan 10 ilaç verileri aşağıdaki gibidir. Yine hemen yanında parantez içerisinde güven katsayısı ve satış adedi verilmiştir.

1. BUDECORT, PEDIFEN (121) ==> VENTOLIN (120) conf:0.99

2. CORTAIR, KLAMER (120) ==> VENTOLIN (118) conf:0.98
3. MUSKAZON, RENNIE (118) ==> ARVELES (115) conf:0.97
4. LEVOTIRON, PANOCER (114) ==> AFERIN (108) conf:0.95
5. ARVELES, FERROZINC (111) ==> TERAD3 (101) conf:0.91
6. GERAL, PANOCER (106) ==> ARVELES (99) conf:0.93
7. IBUCOLD, OKSABRON (101) ==> ARVELES (93) conf:0.92
8. NEXIUM, OKSABRON (98) ==> ARVELES (89) conf:0.91
9. NIMES, RENNIE (97) ==> ARVELES (86) conf:0.89
10. CHINKO, IBURAMIN (96) ==> PEDIFEN (85) conf:0.89

Yaz mevsimi için yapılan birliktelik analizi sonucunda en çok satılan 10 ilaç birlikteliği aşağıdaki gibi olup birlikte satılan ilaçların satış sayıları ve güven katsayısı (conf) yanında gösterilmiştir.

1. NIDAZOL, SPASMOMEN (131) ==> DIAFURYL (125) conf:0.95
2. ENDOL, FERROZINC (130) ==> AKSEF (120) conf:0.92
3. AKSEF, FERROZINC (128) ==> ENDOL (118) conf:0.92
4. AKSEF, ENDOL (127) ==> FERROZINC (115) conf:0.91
5. BUDECORT, MACROL (123) ==> VENTOLIN (112) conf:0.91
6. ENDOL, MINOSET (121) ==> AKSEF (109) conf:0.9
7. FERROZINC, MINOSET (118) ==> AKSEF (105) conf:0.89
8. BUDECORT, KLAMER (118) ==> VENTOLIN (104) conf:0.88
9. FERROZINC, MINOSET (113) ==> ENDOL (99) conf:0.88
10. ENDOL, MINOSET (111) ==> FERROZINC (95) conf:0.86

Kış mevsimi için yapılan birliktelik analizi sonucunda en çok satılan 10 ilaç birlikteliği aşağıdaki gibi olup birlikte satılan ilaçların satış sayıları ve güven katsayısı (conf) yanında gösterilmiştir.

1. CORTAIR (165) ==> VENTOLIN (165) conf:1
2. BUDECORT (161) ==> VENTOLIN (156) conf:0.97
3. DIKLORON (160) ==> ENJEKTOR (150) conf:0.94
4. KLAMER (157) ==> VENTOLIN (145) conf:0.92
5. CALPOL (151) ==> IBURAMIN (139) conf:0.92
6. LEVOPRONT (147) ==> AFERIN (130) conf:0.88
7. KREVAL (140) ==> AFERIN (122) conf:0.87
8. OTRIVINE (139) ==> IBURAMIN (118) conf:0.85
9. ILIADIN (136) ==> IBURAMIN (112) conf:0.82
10. LEVOPRONT (133) ==> IBURAMIN (107) conf:0.80

4. TARTIŞMA VE SONUÇ

Bu çalışmada bir eczanedeki bir yıllık ilaç satış verilerinin analiz edilerek, bir reçete ile birlikte satılan diğer ilaçlardan birlikte alınan ilaçların belirlenmesini sağlamaktır. Birliktelik analizi mevsimlere göre yapılmış ve en çok birlikte satılan 10 ilaç belirlenmiştir. Kış aylarında solunum yollarındaki iltihaplanma için kullanılan CORTAIR ile akciğerdeki hava yollarını genişleterek daha kolay nefes almayı sağlayan VENTOLIN ilacının birlikte satıldığı görülmüştür. Yaz mevsiminde ise ağrılı bağırsak spazmlarını azaltan SPASMOMEN ile bakteri ve parazitlerin sebep olduğu enfeksiyonları tedavi eden NIDAZOL adlı antibiyotik ilacını birlikte alanların bakteri kökenli ishal tedavisinde kullanılan DIAFURYL adlı ilacı da aldığı görülmüştür. İlkbahar mevsiminde solunum yollarındaki iltihaplanmayı azaltmak için kullanılan BUDECORT ile solunum yollarında tıkanıklık giderici, iltihap önleyici, ateş düşürücü ve ağrı kesici bir ilaç olan PEDIFEN alanların akciğerdeki hava yollarını genişleterek daha kolay nefes almayı sağlayan VENTOLIN ilacını da aldığı

görülmüştür. Kış aylarında solunum yollarındaki iltihaplanma için kullanılan CORTAIR ile bronşlar ve akciğerlerle ilgili hastalıklarda ve soğuk algınlığına, üşütmeye bağlı solunum yollarının iltihaplanması durumlarında solunum yollarındaki balgamı eritici ve atılımını kolaylaştırıcı ASIST ilacını alanların akciğerdeki hava yollarını genişleterek daha kolay nefes almayı sağlayan VENTOLIN ilacını da birlikte aldığı görülmüştür. Bu verilere bakıldığında mevsimler değişmesine rağmen bu bölgedeki insanların genelde solunum yolları ile ilgili rahatsızlıklar yaşadığı söylenebilir.

İlaç sektörü üzerine veri madenciliği ve yapay zekâ yöntemleri ile çeşitli uygulamanın olduğu görülmektedir (Cheng ve Sutariya, 2012; Eme vd., 2018; Chen vd., 2001). Delibaş (2010) da buradaki çalışmaya benzer şekilde Apriori algoritması ile mevsimlere, aylara ve yıllara göre ilaçların birliktelik analizini incelemiş ve buradaki çalışmadan farklı olarak ilaç adları yerine endikasyonların birlikteliğini incelemiştir. Nishtala ve diğ. (2018) de çalışmalarında olumsuz ilaç olayları ile ilişkili ilaç kombinasyonlarını belirlemek için birliktelik analizini kullanmıştır. Chazard ve diğ. (2011) ise olumsuz uyuşturucu olaylarını belirlemek için birliktelik analizi ve karar ağaçlarını kullanmıştır. Bu çalışmada ortaya çıkan birlikte ilaç alımları her bir eczane için farklılık gösterebilir. Aynı zamanda her bir bölge için de farklılık gösterebileceği gibi farklı zamanlar için de değişiklik gösterebilir. Örneğin bir bölgede görünen salgın bir hastalık birlikte alınan ilaç durumunu etkileyeceği gibi yalnızca belirli bir hastalığa odaklanan bir sağlık kuruluşuna yakın bir eczanenin birlikte alınan ilaçları da değişiklik gösterecektir. Bu nedenle bu tür çalışmaların eczane, yakında bulunan sağlık kuruluşları, zaman, mevsim, salgın hastalıklar vb. birçok durumdan etkileneceğini söylemek doğru olacaktır.

KAYNAKÇA

- Akpınar, E., Kasapbaşı, M. C. (2019). Sağlık Sigortacılığında Eczane-İlaç Üretici Firması Arasında İlişkilendirme Analizi. *Haliç Üniversitesi Fen Bilimleri Dergisi*, 2(1), 35-47.
- Albayrak M. (2017). Bilimsel araştırmalarda veri madenciliği kullanımı. *IJSSER*, 3(3): 752-756.
- Altıntaş, Y. (2010). Veri madenciliğinin tıpta kullanımı ve bir uygulama: hemodiyaliz hastaları için risk seviyelerine göre risk faktörlerinin etkileşimlerinin incelenmesi. *Ulusal Tez Merkezi*, 269710: 1-3.
- Aydemir, E. (2018). *Weka ile Yapay Zekâ*, Seçkin Yayınevi, Ankara.
- Bilen, Ö., Ökten, A., Gökalp, F. (2012). İstanbul'da Suçun Kentsel Sorun Algısındaki Yerinin Birliktelik Kuralları ile İncelenmesi. *Megaron*, 7(1), 26-35.
- Bramer, M. (2007). *Principles of Data Mining*. London:Springer
- Cao, Y., Zhu, J., Gao, F. (2016, September). An algorithm for mining moving flock patterns from pedestrian trajectories. In *Asia-Pacific Web Conference* (pp. 310-321). Springer, Cham.
- Chazard, E., Ficheur, G., Bernonville, S., Luyckx, M., Beuscart, R. (2011). Data mining to generate adverse drug events detection rules. *IEEE Transactions on Information Technology in Biomedicine*, 15(6), 823-830.
- Chen, Y., Thosar, S. S., Forbess, R. A., Kemper, M. S., Rubinovitz, R. L., Shukla, A. J. (2001). Prediction of drug content and hardness of intact tablets using artificial neural network and near-infrared spectroscopy. *Drug development and industrial pharmacy*, 27(7), 623-631.
- Cheng, F., Sutariya, V. (2012). Applications of artificial neural network modeling in drug discovery. *Clin. Exp. Pharmacol*, 2(3), 1-2.
- Delen, D., Walker, G., Kadam, A., (2005). 'Predicting breast cancer survivability: a comparison of three data mining methods', *Artificial Intelligence in Medicine*, 34 (1), 113-127.

- Delibaş, E. (2010). *Birliktelik Analizi İle Reçeteli İlaç Satışları Üzerinde Bir Uygulama*. Yüksek Lisans Tezi, Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü, Sivas.
- Delibaş, E. (2010). *Birliktelik Analizi İle Reçeteli İlaç Satışları Üzerinde Bir Uygulama*. Yayınlanmamış Yüksek Lisans Tezi, Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü, Sivas.
- Dener, M., Dörterler, M., Orman, A. (2009). Açık kaynak kodlu veri madenciliği programları: WEKA’da örnek uygulama. *Akademik Bilişim*, 9, 11-13.
- Eme, O., CA, U. U., Uwazuruike, F. O., Ukpai, C. U. (2018). Computer-based Drug Sales and Inventory Control System and its Applications in Pharmaceutical Stores. *International Journal of Education and Management Engineering*, 8(1), 30.
- Erdem, S., Özdağoğlu, G. (2008). Ege Bölgesi’ndeki Bir Araştırma ve Uygulama Hastanesinin Acil Hasta Verilerinin Veri Madenciliği ile Analiz Edilmesi.
- Ertuğrul, İ., Organ, A., Şavlı, A. (2013). Veri madenciliği uygulamasına ilişkin PAÜ hastanesinde hasta profilinin belirlenmesi. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 19(2), 97-103.
- Han, J. ve Kamber M., “Data Mining Concepts and Techniques”, Morgan Kaufmann Publishers, 2001.
- Hand, D., Mannila, H., Smyth, P. (2001). *Principles Of Data Mining*. Cambridge: MIT Press.
- Kalikov, A. (2006). “Veri Madenciliği ve Bir E-Ticaret Uygulaması”, Yüksek Lisans Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü.
- Koyuncugil, A., Özgülbaş, N. (2009). Veri madenciliği: Tıp ve sağlık hizmetlerinde kullanımı ve uygulamaları. *Bilişim Teknolojileri Dergisi*, 2(2).
- Lavrač, N. (1999). Selected techniques for data mining in medicine. *Artificial intelligence in medicine*, 16(1), 3-23.
- Nishtala, P. S., Chyou, T. Y., Held, F., Le Couteur, D. G., Gnjjidic, D. (2018). Association rules method and big data: Evaluating frequent medication combinations associated with fractures in older adults. *Pharmacoepidemiology and Drug Safety*, 27(10), 1123-1130.
- Oğuzlar, A. (2004). Veri Madenciliğinde Birliktelik Kuralları, *Öneri*, 6 (22), 315-321.
- Özbay, Ö. (2015). Veri madenciliği kavramı ve eğitimde veri Madenciliği uygulamaları. *Uluslararası Eğitim Bilimleri Dergisi*, (5), 262-272.
- Terzi, M. (2019). Data mining applications in health sector in Turkey. *BSJ Health Sci*, 2(2): 45-48.
- Uslu, M. (2018). Birliktelik Kuralları Analizi (Association Rules Analysis). Retrieved 05.06.2019, from <https://www.veribilimi.co/associationrulesanalysis/>
- Wasan, S. K., Bhatnagar, V., Kaur, H. (2006). The impact of data mining techniques on medical diagnostics. *Data Science Journal*, 5, 119-126.
- Yıldırım, P., Uludağ, M., Görür, A. (2008). Hastane Bilgi Sistemlerinde Veri Madenciliği. *Çanakkale On Sekiz Mart Üniversitesi Akademik Bilişim*.

YÜKSEKÖĞRETİMDE NESNELERİN İNTERNETİ İLE İLİŞKİLİ UYGULAMALAR VE YAKLAŞIMLARIN İNCELENMESİ⁺

INVESTIGATION OF APPLICATIONS AND APPROACHES RELATED TO INTERNET OF THINGS IN HIGHER EDUCATION

Sevcan FAZLA*

Deniz Mertkan GEZGİN**

Öz

Nesnelerin interneti (IoT) teknolojisi kavramı, çeşitli haberleşme protokolleri vasıtasıyla birbirine bağlanıp iletişime geçen, veri paylaşan elektronik cihazların oluşturdukları akıllı ağ sistemi olarak tanımlanmaktadır. Özellikle endüstriyel faaliyet gösteren kuruluşlar üretimi ve verimi arttırmak, zaman ve maliyet açısından kar sağlamak, müşteri memnuniyetini gerçekleştirmek, karar vermeyi geliştirmek için IoT teknolojisini kullanmaktadır. Son zamanlarda birçok sektörde kullanımı yaygınlaşan ve sisteme entegre edilen IoT teknolojisinin yükseköğretimde kullanılması ve oluşabilecek olumlu ve olumsuz etkileri tartışılmaktadır. Olumlu yönden, yükseköğretimde karşılaşılan eğitim ve öğretime engel teşkil edebilecek fiziksel lokasyon, ekonomik, coğrafik ve eğitim dili kaynaklı sorunlara karşı IoT'un çözümler getireceği düşünülmektedir. Olumsuz olarak ise makineleşmenin diğer sektörlerde olduğu gibi güvenlik zafiyetleri ortaya çıkaracağı düşünülmektedir. Bu çalışmada, IoT teknolojisinin yükseköğretimde kullanım amaçları ve geliştirilen uygulamalar incelenmiştir. Son olarak, inceleme bulguları üzerinden tartışmalar yürütülmüş ve çeşitli senaryolar ile öneriler sunulmuştur.

Anahtar Kelimeler: *IoT, nesnelerin interneti, education, teknoloji, yükseköğretim.*

Abstract

Internet of Things (IoT) technology, various communication protocols, Internet connection, can be defined as an intelligent network system of electronic devices that share data recently. Especially industrial organizations use IoT technology to increase production and efficiency, to make profit in terms of time and cost, to realize customer satisfaction and to improve decision making. Recently, the use of IoT technology, which has become widespread in many sectors and integrated into the system, in higher education and the positive and negative effects that may occur are discussed. Positively, it is thought that IoT will provide solutions to physical location, economic, geographical and educational language problems that may hamper education and training in higher education. As a negative, it is thought that mechanization will bring about security weaknesses as in other sectors. In this study, the aims of the use of IoT technology in higher education and the developed applications have been examined. Subsequently, discussions were conducted on the findings of the investigations and various scenarios with recommendations were presented.

Keywords: *IoT, internet of things, education, technology, higher education.*

⁺ Çalışmanın bir bölümü 2015 yılında gerçekleştirilen 10th International Balkan Education and Science Congress 'de "Applications and Availability of The Internet of Things and M2M Concepts in Education Area" başlıklı bildiri ile sözlü olarak sunulmuştur.

* Yüksek Lisans Öğrencisi, Trakya Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, sevcanfazla@trakya.edu.tr, ORCID: 0000 0003 4527 0373

** Doç. Dr., Trakya Üniversitesi, Eğitim Fakültesi, Bilgisayar ve Öğretim Teknolojileri Eğitimi, mertkan@trakya.edu.tr, ORCID: 0000-0003-4688-043X


1. GİRİŞ

Nesnelerin interneti(Internet of Things-IoT) kavramı ilk olarak 1999 yılında Kevin Ashton tarafından ortaya atılmış ve Olivetti Research Ltd. ve Xerox PARC laboratuvarı tarafından, insan ve bilgisayar arasındaki etkileşimi geliştirmek ve fiziksel ortam boyunca kullanılabilir hale getirmek için tasarlanmıştır. IoT için alanyazında farklı tanımlar (Atzori, Iera ve Morabito, 2010; Chui, Loffler, Roberts, 2010) bulunsa da bu çalışmada “*Nesnelerin iletişimi için fiziki bir varlığı olan canlı cansız her nesnenin veri ağlarıyla bağlantılı olduğu bir iletişim ağı*” olduğu tanımını verebiliriz (Erturan ve Ergin, 2017). IoT kapsamında, internete bağlı olan her türlü nesnenin insanla birebir etkileşime girmeden, bireylerin ihtiyaçlarını gidermek amacıyla internet üzerinden veri paylaşımları yoluyla gerçekleştirilen sistemler bulunmaktadır (Arslan ve Kırbaş, 2016). Bu açıdan düşünüldüğünde IoT, internetin oluşturduğu ağ yapısında yer alan elektronik cihazların artık birbiri ile akıllı bir şekilde iletişime geçip, mesaj, bilgi ve veri paylaşarak anlaşmalarını sağlamaktadır. IoT’un oluşturduğu sistemde insanlar, makineler ve elektronik aygıtlar gibi nesnelere bulunmaktadır. Nesnelere arasında işleyen bu iletişim sürecinde insandan-insana iletişim, insandan-makineye karşılıklı iletişim ve son olarak makineden-makineye iletişim olmak üzere üç farklı iletişim şekli bulunmaktadır (Lee ve Crespi, 2010). Bu iletişim şeklinde verinin iletimini sağlayan nesnelere interneti sistemi de üç bölüme ayrılmaktadır. Bunları sırasıyla Radyo Frekanslı (RFID: Radio Frequency Identification-Radyo Frekanslı Tanımlama) ile tanımlama, Makineler arası haberleşme, Yakın saha haberleşmesi (NFC) olarak özetleyebiliriz (Agraval ve Vieria, 2013). IoT temelli mimarilerde ise IoT iletişim modellerini dört grupta inceleyebiliriz:

1. *Nesneden Nesneye İletişim Modeli:* IP ağları veya internet dâhil olmak üzere birçok ağ türü üzerinden birbirleriyle veya ara uygulama sunucusu üzerinden doğrudan bağlanan ve iletişim kuran iki veya daha fazla cihazı temsil etmektedir.
2. *Nesne-Bulut İletişim Modeli:* Cihazların doğrudan bir internet bulut hizmetine bağlanmasıdır.
3. *Nesneden Ağ Geçidine Modeli:* İnternet cihazı ile bulut bilgi işlem servisleri arasında, yerel bir ağ geçidi cihazında çalışan ve birkaç işlevsellik (veri ve protokol çevirisi gibi) ve güvenlik sağlayan bir yazılım uygulamasından oluşan bir sistemdir.
4. *Arka Uç Veri Paylaşımı Modeli:* Kullanıcıların bir bulut hizmetindeki veri nesnelerini diğer kaynaklardan gelen verilerle birlikte analiz etmelerini ve dışa aktarmalarını sağlayan bir iletişim mimarisi sunmaktadır (Banica, Burtescu ve Enescu, 2017).

Şekil 1’de nesnelere interneti mimarisine bir çözüm örneği gösterilmiştir.

Şekil 1. IoT ve Bulut Destekli Bir Mimari (Sam Solutions, 2018)



(Devices: Aygıtlar; Gateways: Geçiş Kapıları; Data System: Veri Sistemi; Data Center: Veri Merkezleri; Cloud: Bulut Yapısı)

IoT teknolojisinde cihazlar genellikle düşük enerji tüketimi ile çalışan işlemcilere sahip elektronik sensörler ve kablosuz ağ bağlantısına sahiptirler. Bu cihazlar, sensörleri sayesinde, sıcaklık, nem, basınç, ses, yer çekimi ve hareketi algılayabilmekte ve cihazın üzerinde bulunan yazılım vasıtasıyla ölçüm verileri internet üzerinden iletelebilmektedir (Sha vd., 2018). Günümüzde nanoteknolojinin getirdiği imkanlar ile kısıtlı alanlara gömülü yazılımlar entegre edilebilmektedir. Bu sayede nesnelerin neredeyse tamamı akıllı cihaz haline gelmiştir. Akıllı saatler, akıllı gözlükler, akıllı telefonlar, RFID kartlar gibi cihazlar bilgiyi işleyip akabinde kendi başlarına karar alabilmektedir (Özdemir, Nursaçan ve Nursaçan, 2018). IoT’de kullanılan cihazların iletişimde ise yoğunlukla Wi-Fi, IEEE 802.15.4, Bluetooth, Z-wave, 6LoWPAN ve LoRaWAN iletişim teknolojileri kullanılmaktadır (Khalil ve Özdemir, 2017). IoT Teknolojisi sayesinde farklı büyüklükteki cihazlar birbirine bağlanmaktadır. Böylelikle oluşan bu ağ ortamında sensörler, algılayıcılar ile alınan veriler bilgiye dönüştürülüp ilgili alıcı cihaza gönderilmektedir. IoT’un kullanımı henüz çok yaygın olmamasına rağmen aktif olarak kullanıldığı sektör ve projelerin sayısı günden güne artmaktadır. IOT ile sağlık uygulamaları başta olmak üzere bina\ev otomasyonları, taşımacılık, perakende, akıllı altyapı -şehir uygulamaları, akıllı üretim, tarım, ekonomi, otomotiv ve giyilebilir teknolojilerle bireysel faaliyetler daha kolay, bu doğrultuda yaşam şartları ise kolay ve standardı daha yüksek hale dönüşmüştür (Weinberg, Milne ve Andonova, 2015). Çeşitli alanlarda kullanılan IoT örnekleri incelendiğinde, yoğunlukla Endüstriyel sektörlerde IoT uygulamaları daha fazla geleneksel sistemlere entegre edilmiş veya yeni projelerle iş yükünün azalması, verimin artması ve müşteriye iyi hizmet verilebilmesi, hata ve güvenlik kontrolünün geliştirilmesi amaçlanmıştır. Bu yüzden endüstriyel anlamda üç husus dikkat çekmektedir: Yazılım, otomasyon ve cihaz (Vollimum, 2018).

Şekil 2. Endüstriyel Olarak Nesnelerin İnterneti Sistemi (Voltimum, 2018)



IoT teknolojisinin kullanıldığı sektör ve uygulamalar kapsamında tarım sektöründe ülkemizde akıllı tarımın geliştirilmesi ve desteklenmesi amacıyla Agritech projesi sürdürülmektedir. Proje ile IoT destekli teknolojiler kullanarak tarım alanlarının gözetilmesi ve araştırılması sağlanmaktadır. (Agritech, 2017). Bir başka proje olarak ise Turkcell'in Akıllı Tarım projesi ile tarım alanlarının nem, sıcaklık, iklimlendirme üniteleri ve sulama pompalarının kontrol edilmesini sağlayan sera takip çözümü bulunmaktadır. Böylelikle çiftçilere kolaylıklar sağlanmaktadır. Sağlık sektöründe IoT kullanımı ile bazı durumlarda, hastalar, acil servisi veya hastaneyi bile ziyaret etmek zorunda kalmadan hizmet alabilmektedir. Nesnelerin İnterneti destekli sağlık hizmetlerinin en açık ve popüler uygulamalarından Autobed, Telehealth uzaktan sağlık izleme sistemleridir (Dermedya, 2018). Böylelikle hastaların daha konforlu, daha güvenli ve daha sağlıklı bir şekilde yaşamlarını sürdürmeleri sağlanmaktadır. Zaman içerisinde IoT'un devamlı gelişen ve genişleyen yapısı sayesinde, endüstriyel ve perakende anlamda başlayan projeler diğer sektörlerde de IoT teknolojisinin kullanılmasını sağlamıştır. Endüstri 4.0 kapsamı içerisinde bir payda olan IoT'a eğitim kurumlarında, eğitim planlamalarında yer vermeye başlanmıştır. Çünkü bu kadar büyük ölçekli ve önem taşıyan ve geleceğe yön verecek teknolojilerin ve gelişmelerin öncülü işaret edilen IoT'un farklı alanlarda kullanılmasının yanı sıra, geleneksel yüz yüze eğitim ortamlarında ve açık ve uzaktan öğrenme sistemlerinde kullanılmaması düşünülememektedir (Altınpulluk, 2018). Endüstride gerçekleştirilen devrimin, eğitim açısından da ortaya koyulması hedeflenmektedir. Bu açıdan öğretmen ve öğrencinin kaynaklara erişimini kolaylaştırmak, eğitimin standardını yükseltmek ve aynı zamanda teknoloji doğumlu Z kuşağının adapte olduğu teknoloji ile destekli bir eğitim ortamını oluşturmak için IoT teknolojisinden yararlanılmaya çalışılmaktadır. Bu bağlamda çalışmada yükseköğretimde hâlihazırda kullanılan IoT destekli uygulamalar, yaklaşımlar, öngörüler alanyazında konuyla ilgili yürütülmüş çalışmalar kapsamında incelenecektir.

2. YÖNTEM

Bu çalışmada veri toplama yöntemi olarak doküman analizinden faydalanılmıştır. Doküman analizi kapsamında geliştirilen ve yaygınlaşan bu yeni teknolojinin, avantajları-dezavantajları, yükseköğretimdeki uygulamaları ve yaklaşımlar hakkında bilgi toplamayı sağlayan yazılı materyaller ve kaynakların analizi yapılmıştır. Yükseköğretimde yeni teknolojik altyapının oluşturulması, eğitim-öğretim faaliyetlerine katma değer kazandıracak yeni teknolojilerin kurumlara ve öğretim sistemlerine entegre edilmesi ile eğitimin önündeki bazı bariyerlerin ortadan kaldırılması

hedeflenmektedir. Okul ile akademisyen, okul ile öğrenci ve son olarak akademisyen ile öğrenci arasındaki işbirliğini ortaya koyabilmek için gelecek neslin teknoloji yatkınlığı, kullanım amaçları ve becerileri doğrultusunda çağdaş, yenilikçi eğitim ve öğretim ortamları tasarlamak gerekmektedir. Çalışmada incelenen dokümanlar, 2010 – 2019 yılları arasında TR Dizin, EBSCO, Scopus, ELSEVIER, Springer veri tabanlarında yayınlanmış makaleler ve bu yıllar arasında gerçekleştirilmiş uluslararası konferanslarda sunulmuş ve tam metni yayınlanmış bildirilerden elde edilmiştir. Dokümanların taranmasında nesnelere interneti, IoT, yükseköğretim, eğitim, giyilebilir teknolojiler anahtar kelimeleri kullanılmıştır.

3. BULGULAR

Çalışma kapsamında alanyazın incelendiğinde IoT teknolojisi destekli eğitim uygulamalarının yetersiz olduğu görülmüştür. Her ne kadar akademik çalışmalar sınırlı olsa da eğitim alanında özel ve kamu kuruluşları tarafından yapılan projelerin ve araştırmaların yürütüldüğü görülebilmektedir. Alanyazında yükseköğretimde dijital dönüşümün yaşanabilmesi için gerekli teknolojilerden biri olan IoT'nin eğitimdeki uygulama amaçları “enerji yönetimi ve gerçek zamanlı ekosistem izleme, öğrencinin sağlık hizmetlerini izleme, sınıf erişim kontrolü ve öğretme-öğrenmeyi geliştirme” olmak üzere dört gruba ayrılmaktadır (Bagheri ve Movahed, 2016).

Sınıf erişim kontrolü ve öğretme-öğrenmeyi geliştirmek amaçlı Belgrad Üniversitesi'nde yürütülen bir çalışmada (Horowitz, 2015), sınıf içinde oluşan veya değişen sıcaklık, nem ve karbondioksit seviyeleri algılayıcılar sayesinde ölçülmüştür. Elde edilen verilerden ortaya çıkan faktörlerin öğrencinin odaklanma düzeyine etkisi incelenmiştir. Sonuçlar ışığında öğrencinin odaklanma düzeyi ile ilgili bir standart ilişki belirlenmek istenmiştir.

Enerji Yönetimi ve gerçek zamanlı ekosistem izleme amaçlı Wang (2013) tarafından yapılan çalışmada, “Yeşil Kampüs” projesi altında bilgisayar laboratuvarlarında klima ve bilgisayarların gereksiz enerji tüketimini engellemek ve böylece daha yeşil bir kampüs oluşmasını sağlamak adına IoT teknolojisi destekli bir sistem geliştirilmiştir. Yazılım, otomasyon ve cihazları kapsayan projede geliştirilen yazılım ile açık olan ve kullanılmayan bilgisayarların kapatılması, klimaların belirli derecelerde ve kullanılmadığında enerjisinin kesilmesi sağlanmıştır. Yazılımın verileri aldığı algılayıcı sensör ve wi-fi cihazları da sistemde yer almaktadır. Çalışma sonucunda enerji tasarrufu açısından olumlu sonuçlar elde edilmiştir.

Öğretme-öğrenmeyi geliştirme amaçlı Gómez ve arkadaşları (2013) tarafından yapılan bir çalışmada, Kolombiya'da Cordoba Üniversitesinde Sistem Mühendisliği bölümündeki “Bilgisayar Sistemlerine (Donanım) Giriş” dersine kayıtlı öğrencilerle bir pilot çalışma yürütülmüştür. QR Kod, Karekod ve nesnelere interneti teknolojisi yardımıyla öğrenciler mobil cihazlarıyla nesnelere bağlanmış ve bazı zorluklar yaşadıkları bu donanım konusunda yararlı pratikler geliştirmişlerdir. Yapılan uygulamalar deneysel bir desen altında yürütülmüş bir çalışma ile desteklenmiştir. Çalışmanın bulguları sonucunda deney grubunun, kontrol grubuna göre bu derste daha başarılı olduğu rapor edilmiştir. Çalışmadan elde edilen sonuçlar, IoT'un öğretimi desteklemek için bir araç olarak kullanılabilmesi ve böyle uygulamaların öğrencinin akademik performansı üzerinde olumlu anlamda katkı sağlayabileceğini göstermektedir.

Abbasy ve Quesada (2017) tarafından yapılan istatistiksel çalışmada IoT Teknolojisinin Hiper bağlantı, işbirliği ve araştırma olanakları gibi bazı durumlara etkisi olduğu tespit edilmiştir. Çalışma sonucunda IoT ile bağlı nesnelere elde edilen verilere dayanarak IoT temelli teknolojinin öğrencilerin özel eğitim ihtiyaçlarını tahmin edebilecek akıllı e-öğrenme sistemlerinin geliştirilmesine olanak sağlayacağı öngörülmektedir. Bu açıdan IoT'nin eğitim ortamında kullanılmasının, Bilgi ve İletişim Teknolojileri (BİT) temelli eğitim sistemleriyle aynı etkiye sahip olabileceği, ayrıca öğrenme sürecini daha motive edici ve etkili hale getirebileceği söylenebilmektedir (Priestley, 2014).

Sari, Ciptadi ve Hardyanto (2017) tarafından yapılan bir çalışmada akıllı yerleşke kapsamında akıllı park sistemi, akıllı bina, odalar ve akıllı eğitim altyapıları ele alınmıştır. PGRI Yogyakarta üniversitesinde bir durum çalışması olarak ele alınan araştırma neticesinde akıllı kampüs sayesinde, kampüse dış varlıklar tarafından çevrimiçi olarak bağlanması mümkün olmakta ve böylece teknolojiye dayalı öğretim yaklaşımı gerçek zamanlı olarak gerçekleştirilebilmektedir.

Ur Rahman, Deep ve Rahman (2016) tarafından Hindistan'da yapılan bir çalışmada ise üniversitelerde sosyal medya uygulamaları, BİT ile IoT'un entegre edilmesi ve güncellenmesinin eğitimciler, öğrenciler ve enstitüler için akıllı eğitim ortamları oluşturmak hususunda fırsatlar doğurduğu ifade edilmektedir. Bu akademik çalışmalardan elde edilen bilgiler doğrultusunda IoT teknolojisinin eğitime yeni bir form getirmesi yönünden geleceğin teknolojileri arasında olduğu öngörüsü kabul edilmektedir. Ayrıca özel sektörün öncü isimlerinden Cisco ve Google gibi büyük ölçekli firmalarının da eğitim-öğretim uygulamaları için IoT teknolojisine yatırım yapmaları bunu desteklemektedir.

Bulgular kısmında son olarak, alanyazın doğrultusunda eğitim ortamlarında IoT destekli kullanımları aktif olarak devam eden uygulamalara örnekler de verebiliriz. Bunlar etkileşimli tahtalar, akıllı kameralar, tablet bilgisayarlar ve e-dokümanlar, güvenlik ve giriş işlemlerini kolaylaştıran sensörlü öğrenci kimlik kartları, üç boyutlu yazıcılar, akıllı iklimlendirme sistemleri, sıcaklık, nem, karbondioksit sensörleri, izleme sistemleri ve ağ tabanlı kapı kilitleri olarak sıralanabilir (e-Learning Industry, 2016).

4. SONUÇ ve TARTIŞMA

Yükseköğretimde nesnelere interneti teknolojisi üzerine yürütülen uygulamaların ve yaklaşımların incelendiği bu çalışmada yapılan alanyazın incelemesi sonucunda IoT teknolojisinin eğitimin üzerinde engel teşkil eden fiziksel konum, coğrafya, dil ve ekonomik sebepleri ortadan kaldırmak için büyük bir potansiyele sahip olduğu düşünülmektedir. Çünkü IoT teknolojisi sayesinde engeller ortadan kalktığında teknoloji ve eğitimin entegrasyonu daha hızlı hale gelecek ve öğrenme daha ulaşılabilir bir şekilde gerçekleştirilebilecektir. Bunun sonucu olarak öğrenci hatasız ve güvenilir bilgiye kolay ulaştığında ve her türlü kaynaktan bilgiyi almaya başladığında öğrenme potansiyeli artarak performansı gelişebilecektir (Banica vd., 2017). IoT, özellikle geleneksel eğitim ve uzaktan öğrenme alanlarında da etkin bir kullanım alanı bulmaya başlamıştır (Altınpulluk, 2018). Zaman içerisinde IoT teknolojisinin üniversitelerin çalışma şeklini önemli ölçüde değiştirebileceği düşünüldüğünde, bu birçok disiplinde, her seviyede öğrencinin öğrenmesinin gelişmesi mümkün görünmektedir. Dünyada üniversitelerin büyük bir potansiyele sahip olduğu bilinmektedir. Bazı gelişmiş ülkelerde teknolojik gelişmelerin açığa çıkarılması için üniversitelerde Ar-ge laboratuvarları kurulmakta ve hükümetler tarafından ciddi yatırımlar yapılmaktadır. Ayrıca üniversiteler, devletler için öncü ve lider bir konumdadır. Üniversitelerin ellerinde bulundurduğu bu misyon ve vizyonu doğru kullanıp, yeni teknolojilerin kullanmaları, devletin diğer eğitim kurumlarının da bu alt yapıya geçmesi için fırsatlar sağlayacaktır. Bu açıdan, akademisyenler, araştırmacılar ve öğrenciler, IoT sistemlerinin, cihazlarının, uygulamalarının ve hizmetlerinin keşfedilmesine ve geliştirilmesine öncülük etmelidirler (Aldowah, Rehman, Ghazal ve Umar, 2017). Eğitim maliyeti açısından ise eğitim için harcanan yüksek giderlerin minimum seviyeye indirgenmesi için de IoT'un etkin rol alacağı öngörülmektedir (Selinger, Sepulveda ve Buchan, 2013). Geleneksel sınıf içerisindeki etkinliklerde algılayıcı cihazlar, giyilebilir teknolojiler, kameralar ve akıllı saatler gibi aygıtlar vasıtasıyla eğitim-öğretim ortamının öğrencinin öğrenme performansını arttırmak için faydalı veriler elde edilebilir. Bunlar sınıf içindeki sıcaklık değeri ve oksijen miktarı gibi verileri, öğrencilerin derse ilgisini ve konsantrasyonu hakkında varsayımlarda bulunabilecek öğrencinin fiziksel veri (kalp atışı, vücut ısısı vb.) ölçümleri de olabilir. Elde edilen verilerden, zaman içerisinde büyük veriler ve veri madenciliği analiz teknikleri ile anlamlı sonuçlar çıkarılabilir. Bu elde edilebilecek sonuçlar sayesinde, öğrenci için en etkin olan öğrenme stili

belirlenip bu şekilde öğretim ortamlarının yaratılması sağlanabilir. Nesnelerin İnterneti henüz tam anlamıyla geleneksel sistemlerin yerini almamış olmasına ve kullanım yaygınlığını yakalayamamış olmasına rağmen, özellikle Yapay Zekâ ile ilişkili yapılarla bütünleşerek geleceğe yön verecek potansiyeli taşımaktadır (Altınpulluk, 2018).

E-öğrenme açısından da, IoT teknolojisinin olumlu etkileri olacağı düşünülmektedir. Çünkü IoT gibi yeni teknolojiler dijital dünyada hızla gelişmekte ve bu gelişim geleneksel eğitim sistemini ölçeklenebilir hale getirmektedir. Böylece E-öğrenme süreci, hızlı dinamik değişimlere uyartılabilir, çok sayıda fiziksel ve sanal etkileşimli nesnenin bulunduğu topoloji ile esnek, daha verimli hale gelmektedir. Bununla birlikte IoT teknolojisinin, bağlı nesnelere elde edilen verilerin çalışmasına dayanarak öğrencilerin özel eğitim ihtiyaçlarını tahmin edilip belirlenebileceği akıllı E-öğrenme sistemlerinin geliştirilmesine olanak sağlayacağı öngörülmektedir (Abbasy ve Quesada, 2017).

Mobil Öğrenme (m-öğrenme) açısından da IoT teknolojisinin olumlu katkıları olacağı öngörülebilmektedir. Çünkü zaman içinde öğrenciler gittikçe artan bir şekilde kâğıt belgelerden, kitaplardan çalışmaktan ve defterlere not almaktan ziyade kendilerine gerekli bilgileri sağlayan ve aynı zamanda kendi hızlarında öğrenme imkânı sunan akıllı telefonlara, tablet ve dizüstü bilgisayarları kullanmayı tercih etmektedirler (Gezgin, 2019). Ek olarak, mobil cihazlar, öğrencilerin e-kitaplara, kısa süreli test sınavlarına, projelere erişmelerine, laboratuvarları ve kursları video biçiminde izlemelerine olanak sağlamakta ve bu durum öğrenciler için çok çekici öğrenme yöntemleri olarak ortaya çıkmakta ve öğretmenler için de yeni öğretim fırsatları yaratmaktadır (Mishra, 2017). Son olarak, gelenekçi öğretim yaklaşımlarına bağlı kalan ve teknoloji yetersizliği olan akademisyenler haricinde mobil cihazların akademik faaliyetlerde kullanım eğilimi akademisyenler için de kolaylık sağlamaktadır. Akademisyenler, IoT ile bağlı cihazları kullanarak hızlı ve güvenilir bir şekilde, her bir öğrenciyle derslerini ve uygulama etkinliklerini uyarlayarak işbirliği yapabilmektedir (Meola, 2016).

Sonuç olarak, üniversitelerde öğrenci merkezli bir sistemin gerekliliği, akademisyen-öğrenci-üniversite arasındaki işbirliğinin sağlanması, kendi kendini yöneten ve problem çözme faaliyetlerinin yanı sıra, video ve oyunlaştırmaya dayalı bir öğrenme stili yaklaşımının bir öğrenme sürecinde odak noktası olduğu düşünülmektedir. Üniversitelerin öğrencilere bu eğitim ortamını sağlayamaması, altyapı ve teknoloji anlamında yeni projelerle öğrenciler için akıllı kampüslerin, sınıfların, laboratuvarların oluşmasından geçmektedir. Lisans hayatını sadece bir projeksiyon cihazı, bilgisayar ve PowerPoint sunum programı ile gerçekleştirilen derslerle geçiren yeni teknolojilerle donatılmış başka bir teknoloji ortamı görmeyen Z kuşağına mensup öğrencilerin üniversitelere olan güvenini, umudunu zamanla kaybetmesine sebep olabilmektedir. Bu açıdan akademisyenlerin de modern teknolojilere ve iletişim yöntemlerine alışmaları, yeterliliklerini arttırmaları gerekmektedir. Devletinde çeşitli projelerle böyle yeni teknolojilerin sisteme entegre edilmesine yardımcı olması ve mevcut projelerle bu teknolojileri sürece dahil etmeleri gerekmektedir.

Çalışma sonucunda alanyazın ışığında IoT ile ilgili bazı kısıtlamalar ve sorunlar da görülmüştür. Teknolojik gelişmeler ışığında IoT gibi yeni bir kavram ortaya atıldıkça, böyle bir teknolojinin yürürlükte olan yaygın geleneksel ve işlevsel modele, standartlara entegre sürecinde problemler yaşanmaktadır. Çünkü geleneksel hali hazırda işleyen sistemin IoT teknolojisine geçiş yapacak özelliklere sahip olmadığı durumlar gözlenmektedir. IoT teknoloji sayesinde kurulan sistemlerde iletişim kanalları ve IoT katmanlarında nesnelerin birbirleri ile iletişimde güvenlik zafiyetleri yaşanabilmektedir (Jing vd., 2014). Son olarak, üniversitelerin IoT teknolojisinin eğitim sektörüne önerdiği tüm değişiklikleri ve yenilikleri kabul edememesi ekonomik sorunlar, altyapı yetersizliği, eğitimcilerin ve öğrencilerin yeni teknolojilerin kullanımı hakkında yeterli bilgiye sahip olmamalarından kaynaklanabilmektedir.

KAYNAKLAR

- Abbasy, M. B., ve Quesada, E. V. (2017). Predictable influence of IoT (Internet of Things) in the higher education. *International Journal of Information and Education Technology*, 7(12), 914-920.
- Adams Becker, S., Cummins, M., Davis, A., Freeman, A., Hall Giesinger, C., & Ananthanarayanan, V. (2017). *NMC horizon report: 2017 higher education edition*. Austin, Texas: The New Media Consortium
- Agraval, S. ve Viera D. (2013). A Survey on Internet of Things, *Abakos*,78-95, ISSN:2316–9451.
- Agritech (2017). Tarımın geleceği: Nesnelerin İnterneti ve Akıllı Tarım Sistemleri. <https://ioturkiye.com/2017/06/tarimin-gelecegi-akilli-tarim-sistemleri/>, (14.06.2019).
- Aldowah, H., Rehman, S. U., Ghazal, S., & Umar, I. N. (2017, September). Internet of Things in higher education: a study on future learning. In *Journal of Physics: Conference Series* (Vol. 892, No. 1, p. 012017). IOP Publishing.
- Altınpulluk, H. (2018). Nesnelerin interneti teknolojisinin eğitim ortamlarında kullanımı. *Açık öğretim Uygulamaları ve Araştırmaları Dergisi*, 4(1), 94-111.
- Arslan, K., & Kırbuş, İ. (2016). Nesnelerin interneti uygulamaları için algılayıcı/eyleyici kablosuz düğüm ilk örneği geliştirme. *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, (1), 35-43.
- Atzori, L., Iera, A., Morabito, G. (2010). “The Internet Of Things: A Survey”, *Computer Networks*, 54, s: 2787–2805
- Bagheri, M., ve Movahed, S. H. (2016, November). The effect of the Internet of Things (IoT) on education business model. In *2016 12th International Conference on Signal-Image Technology & Internet-Based Systems (SITIS)* (pp. 435-441). IEEE.
- Banica, L., Burtescu, E., ve Enescu, F. (2017). The impact of internet-of-things in higher education. *Scientific Bulletin-Economic Sciences*, 16(1), 53-59.
- Chui, M., Loffler, M., Roberts, R. (2010). “The Internet Of Things”, *McKinsey Quarterly*, 2, s: 1-9.
- Deng, Z., & Sang, Q. (2010). The applications and thinking of the Internet of Things in education. *Journal of WUXI Institute of Technology*.
- DerMedya (2018). Sağlık Sektöründe Nesnelerin İnterneti Kullanımı ve Avantajları. <https://www.dermedya.com/tr/post/saglik-sektorunde-nesnelerin-interneti-kullanimi-ve-avantajlari>, (14.06.2019).
- e-Learning Industry (2016). The internet of things smart school infographic. <http://elearninginfographics.com/the-internet-of-things-smart-school-infographic/> adresinden 11.06.2019 tarihinde erişilmiştir.
- Erturan, İ. E.; Ergin, E., (2017). “Muhasebe Denetiminde Nesnelerin İnterneti: Stok Döngüsü”, *Muhasebe ve Finansman Dergisi*, Temmuz, s: 13-30,
- Gezgin, D. M. (2019). The Effect of Mobile Learning Approach on University Students' Academic Success for Database Management Systems Course. *International Journal of Distance Education Technologies (IJDET)*, 17(1), 15-30.
- Gómez, J., Huete, J. F., Hoyos, O., Perez, L., & Grigori, D. (2013). Interaction system based on internet of things as support for education. *Procedia Computer Science*, 21, 132-139.

- Horowitz, E. (2015). A peek at a ‘smart’ classroom powered by the internet of things. <https://www.edsurge.com/news/2015-08-11-a-peek-at-a-smart-classroom-powered-by-theinternet-of-things>, (10.06.2019).
- Jing, Q., Vasilakos, A. V., Wan, J., Lu, J., & Qiu, D. (2014). Security of the Internet of Things: perspectives and challenges. *Wireless Networks*, 20(8), 2481-2501.
- Khalil, E. A., & Özdemir, S. (2017). Reliable and energy efficient topology control in probabilistic wireless sensor networks via multi-objective optimization. *The Journal of Supercomputing*, 73(6), 2632-2656.
- Kortuem, G., Bandara, A. K., Smith, N., Richards, M., & Petre, M. (2013). Educating the Internet of-Things generation. *Computer*, 46(2), 53-61
- Lee, G., & Crespi, N. (2010). Shaping future service environments with the Cloud and internet of things: networking challenges and service evolution. *Leveraging Applications of Formal Methods, Verification, and Validation*, 399-410.
- Meola, A., (2016). How is IoT in education changing the way we learn? , <http://www.businessinsider.com/internet-of-things-education-2016-9>,(13.06.2019).
- Mishra, S., 2017, 12 Modern Learning Practices with Internet of Things i.e. IoT in Education, <http://www.clickonf5.org/126745/modern-learning-practices-iot-education/>
- Özdemir, A., Nursaçan, M. N. N., ve Nursaçan, İ. C.(2018). 2014-2018 Yılları Arasında Nesnelerin İnterneti (IOT) Üzerine Bir Literatür Taraması. *Bandırma Onyedli Eylül Üniversitesi Sosyal Bilimler Araştırmaları Dergisi*, 1(2), 1-22.
- Priestley T. (2014), “Everything is hyper connected in the internet of things,” [Online]. Available: <https://www.wired.com/insights/2014/08/everything-hyper-connected-internet-things>,(18.06.2019).
- Sam Solutions (2018). Internet of Things (IoT) Protocols and Connectivity Options: An Overview. <https://www.sam-solutions.com/blog/internet-of-things-iot-protocols-and-connectivity-options-an-overview/>, (12.06.2019).
- Sari, M. W., Ciptadi, P. W., & Hardyanto, R. H. (2017). Study of smart campus development using internet of things technology. In *IOP Conference Series: Materials Science and Engineering* (Vol. 190, No. 1, p. 012032). IOP Publishing.(April)
- Selinger, M., Sepulveda, A., & Buchan, J. (2013). Education and the internet of everything, how ubiquitous connectedness can help transform pedagogy. CISCO. http://www.cisco.com/c/dam/en_us/solutions/industries/docs/education/education_internet,(13.06.2019).
- Sha, K., Wei, W., Yang T.A., Wang, Z. & Shi, W. (2018). On security challenges and open issues in Internet of Things, *Future Generation Computer Systems*, 83, 326–337.
- Spice, B. (2015). CMU leads google expedition to create technology for “internet of things”. <http://www.cmu.edu/news/stories/archives/2015/july/google-internet-of-things.html>, (10.06.2019).
- Ur Rahman, M., Deep, V., ve Rahman, S. (2016, January). ICT and internet of things for creating smart learning environment for students at education institutes in India. In *2016 6th International Conference-Cloud System and Big Data Engineering (Confluence)* (pp. 701-704). IEEE.
- Voltimum (2018). Nesnelerin İnterneti Nedir ve Nasıl Gelişecek? <https://www.voltimum.com.tr/haberler/nesnelerin-interneti-nedir-ve-nasil>, (12.06.2019).

- Wang, H. (2013). Toward a Green Campus with the Internet of Things-the Application of Lab Management. *world*, 7, 8.
- Weinberg, B. D., Milne, G. R., ve Andonova, Y. G. (2015). ‘‘Internet of Things: Convenience vs. privacy and secrecy’’. *Business Horizons*, s:615-624.