



# ACTA INFOLOGICA

(ACIN)

ISSN: 2602-3563

DECEMBER, 2017

Volume: 1 | Issue:2

ISTANBUL UNIVERSITY, INFORMATICS DEPARTMENT

[dergipark.gov.tr/acin](http://dergipark.gov.tr/acin)

[informatics.istanbul.edu.tr](http://informatics.istanbul.edu.tr)





Aralık (December) 2017  
Cilt (Volume): 1 | Sayı (Issue): 2

**Dergi Sahibi (Owner)**

İstanbul Üniversitesi Enformatik Bölümü  
adına  
Dr. Sevinç Gülseçen

**Sorumlu Yazı İşleri Müdürü  
(Managing Editor)**

Dr. Sevinç Gülseçen

**Editörler (Editorial Board)**

Dr. Çiğdem Erol  
Baş Editör (Chief Editor)

Dr. Serra Çelik

Dr. Emre Akadal

Dr. Fatma Önay Koçoğlu

**Logo Tasarımı (Logo Design)**

Kemal Şahin

**Bilimsel Danışma Kurulu (Advisory Board)**

Prof. Dr. Alp Baray / İstanbul Üniversitesi

Prof. Dr. Alptekin Erkollar / Sakarya Üniversitesi

Prof. Dr. Bekir Sıddık Binboğa Yarman / İstanbul Üniversitesi

Prof. Dr. Birgül Kutlu Bayraktar / Boğaziçi Üniversitesi

Prof. Dr. Çiğdem Arıcıgil Çılan / İstanbul Üniversitesi

Prof. Dr. Erman Coşkun / Sakarya Üniversitesi

Prof. Dr. Hadi Gökçen / Gazi Üniversitesi

Prof. Dr. Haldun Akpınar / Marmara Üniversitesi

Prof. Dr. İbrahim Enis Sınıksaran / İstanbul Üniversitesi

Prof. Dr. Mehpere Timor / İstanbul Üniversitesi

Prof. Dr. Meltem Özturan / Boğaziçi Üniversitesi

Prof. Dr. Nuri Başoğlu / İzmir Teknoloji Enstitüsü

Prof. Dr. Orhan Torkul / Sakarya Üniversitesi

Prof. Dr. Selim Yazıcı / İstanbul Üniversitesi

Prof. Dr. Sevinç Gülseçen / İstanbul Üniversitesi

Prof. Dr. Türksel Kaya Benschir / TODAİE

Prof. Dr. Üstün Özen / Atatürk Üniversitesi

Prof. Dr. Vahap Tecim / Dokuz Eylül Üniversitesi

Prof. Dr. Yasemin Gülbahar Güven / Ankara Üniversitesi

Prof. Dr. Yücel Yılmaz / Kadir Has Üniversitesi

Prof. Dr. Zuhâl Tanrıkulu / Boğaziçi Üniversitesi

*Değerli Enformatik severler,*

*2017 yılının başında yayın hayatına başlayan dergimiz ACTA INFOLOGICA'nın ikinci sayısını yayınlamaktan gurur duyuyoruz. Logomuz "bilge" baykuş bu sayıda, Yapay Sinir Ağları, Destek Vektör Makineleri ve Karar Ağaçları gibi yapay zekâ modellerinin sağlıktan web sitelerine kadar farklı alanlarda uygulamaları, Endüstri 4.0'ın yapıtaşlarından biri olan Nesnelerin İnterneti'nin ekosisteme etkisi ve mobil alışveriş bağlamında Teknoloji Kabul ve Bilgi Sistemleri Beklenti Onaylama Modellerinin ele alındığı araştırmalara eşlik ediyor. DergiPark istatistiklerine göre ilk sayımızda yer alan makalelerin en düşük indirilme sayısı 99 iken en yüksek indirilme sayısı 179 olmuştur. 2602-3563 nolu ISSN ile çıkan ikinci sayımızda yer alan değerli araştırmaların daha da fazla okuyucuya ulaşmasını temenni ederek sizlere bu sayımızı sunuyoruz.*

*Bildiğiniz gibi dergi hazırlamak yoğun emek ve iyi bir ekip gerektirmektedir. Bu sayıda emeği geçen araştırmacılar, hakemler ve dergi kurullarımızın üyelerine minnettar olmakla birlikte siz değerli Enformatik ailesi okuyucularına da ilginiz ve desteğiniz için çok teşekkür ederiz.*

*Hep birlikte ileriye...*

*Sağlıcakla kalın*

**Dr. Çiğdem EROL**

**Acta INFOLOGICA Editörleri adına**

	<u>Sayfa No</u>
<b><i>Yapay Sinir Ağları ile Tahmin ve Sınıflandırma Problemlerinin Çözümü İçin Arayüz Tasarımı</i></b> <i>Ayşe Arı, Murat Erşen Berberler</i>	55 – 73
<b><i>Mobil Alışveriş Bağlamında Sürekli Kullanım Niyetinin İncelenmesi: İki Kuramsal Modelin Karşılaştırılması</i></b> <i>Mehmet Cem Bölen, Üstün Özen, Ersin Karaman</i>	74 – 83
<b><i>Karar Ağaçları ile Bir Web Sitesinde Link Analizi ve Tespiti</i></b> <i>Muhammed Çağrı Aksu, Ersin Karaman</i>	84 – 91
<b><i>Destek Vektör Makineleri ile Fibromiyalji Sendromu Sınıflaması</i></b> <i>Cemile Zontul, Emrullah Hayta, Metin Zontul, Ayça Taş, Yavuz Siliğ</i>	92 – 98
<b><i>Ecosystem Effects of the Industrial Internet of Things on Manufacturing Companies</i></b> <i>Christian Arnold, Kai-Ingo Voigt</i>	99 – 108

# Yapay Sinir Ağları ile Tahmin ve Sınıflandırma Problemlerinin Çözümü İçin Arayüz Tasarımı

Ayşe Arı, Murat Erşen Berberler

## ÖZET

Yapay sinir ağları, sınıflandırma, modelleme ve tahmin gibi birçok günlük hayat probleminin çözümünde başarılı sonuç veren bir yöntemdir. Yapay sinir ağları nöronlar arasındaki bağlantı ağırlıklarını ayarlayarak öğrenme gerçekleştirir. Bu çalışmada tek katmanlı algılayıcılardan Adaline modeli ve çok katmanlı algılayıcı modelini içeren bir yazılım geliştirilmiştir. Bilindiği gibi tek katmanlı algılayıcılar lineer problemlere çözüm üretebilirken lineer olmayan problemlere çözüm üretememiş, lineer olmayan problemler yapay sinir ağları ile çok katmanlı algılayıcı modelinin geliştirilmesi ile çözülebilmektedir. Yazılımın tek katmanlı algılayıcı kısmında mantıksal AND ve OR problemleri doğrusal olarak sınıflandırılabilirken, XOR problemini tek bir doğru ile sınıflandırılmadığı gözlemlenebilmektedir. Çok katmanlı algılayıcı kısmında ise, yapay sinir ağlarında yaygın olarak kullanılan geri yayılım algoritması ile tahmin ve sınıflandırma problemleri çözülebilmektedir. Ağın katman sayısı, katmanlardaki nöron sayısı, iterasyon sayısı, öğrenme oranı, momentum katsayısı, aktivasyon fonksiyonu, normalizasyon yöntemi, başlangıç ağırlıkları gibi parametrelerin değiştirilerek ağın eğitilmesi sağlanabilmekte ve eğitilen ağ test edilerek ağın performans ölçümü yapılabilmektedir.

**Anahtar Kelimeler:** Yapay sinir ağları, geri yayılım, adaline, sınıflandırma, tahmin

## ABSTRACT

Artificial neural networks are a successful method for solving many daily life problems such as classification, modeling and estimation. Artificial neural networks perform learning by adjusting the connection weights between the units. In this study, a software is developed which includes adaline model of single layer perceptron and multilayer perceptron model. As it is known, single layer perceptron model can produce solutions to linear problems, but can not nonlinear problems, they solved by multi-layer perceptron models with artificial neural networks. In the single layer part of the software, it can be observed that while logical AND and OR problems are linearly classified but the XOR problem can not be classified with a single line. In the multilayer perceptron part, it is possible to solve the approach and classification problems with the backpropagation algorithm which is widely used in artificial neural networks. The network can be trained by changing the parameters such as the number of layers in the network, the number of neurons in the layers, the number of iterations, learning rate, momentum constant, activation function, normalization method, initial weights, and network performance can be measured by testing the trained network.

**Keywords:** Artificial neural networks, backpropagation, adaline, classification, prediction.

## Information of Author(s):

\* Ayşe Arı  
ayse.ari@ogr.deu.edu.tr  
Dokuz Eylül Üniversitesi, Bilgisayar Bilimleri Bölümü

Murat Erşen Berberler  
murat.berberler@deu.edu.tr  
Dokuz Eylül Üniversitesi, Bilgisayar Bilimleri Bölümü

\* Contact Author  
Address: Dokuz Eylül Üniversitesi, Bilgisayar Bilimleri Bölümü, İzmir  
Telephone Number: +90 232 3019514

Submit Date: 22.08.2017  
Accept Date: 01.12.2017  
Publish Date: 29.12.2017



## 1. GİRİŞ

Günlük hayatımızda vazgeçilmez bir yere sahip olan bilgisayarın, artık insanlar gibi karar verme ve öğrenme gerçekleştirme yeteneklerini kazanması ile kullanım alanları oldukça genişlemiştir. Matematiksel olarak ifade edilemeyen ve insanlar tarafından çözülmesi zor olan problemlerin çözümünde yapay zekâ yöntemleri kullanılmaktadır. Yapay zekâ yöntemlerinin en temel özelliği, olaylara ve problemlere çözümler üretirken örneklerden, tecrübeden, benzetmelerden öğrenme gerçekleştirme ve karar verebilme yeteneklerinin olmasıdır.

Makine öğrenimi için en popüler yaklaşımlardan biri yapay sinir ağlarıdır. Yapay sinir ağları, geleneksel hesaplama yöntemleri ile çözülemeyen problemlerin çözümünde yaygın olarak kullanılmaktadır.

Öğrenme, genelleme, doğrusal olmama, hata toleransı, uyum, paralellik gibi üstünlüklere sahip olan yapay sinir ağları; görüntü ve sinyal işleme [1], hastalık tahmini [2], gibi tıbbi uygulamalarda; mühendislik [3], üretim, finans [4], optimizasyon, sınıflandırma gibi çok farklı uygulama alanlarında kullanılmaktadır.

Yapay sinir ağları için çeşitli programlama dillerinde birçok kütüphane ve araç geliştirilmiştir. Bunlardan yaygın olarak kullanılan ve genel kabul görmüş olanlardan birkaçı aşağıdaki gibidir [5].

- Stuttgart Neural Network Simulator (SNNS) yapay sinir ağları için Stuttgart Üniversitesi'nde IPVR enstitüsü tarafından geliştirilmiştir bir simulatördür. Sinir ağı uygulamaları ve araştırmaları için etkin ve esnek bir simülasyon ortamı oluşturmak amacıyla yapılmıştır.
- FANN (Fast Artificial Neural Network Library), çok katmanlı algılayıcıları kullanmayı sağlayan, C programlama dilinde yazılmış bir yapay sinir ağı kütüphanesidir.
- JOONE (Java Object Oriented Neural Engine), Java ortamında geliştirilmiş bir yapay sinir ağı kütüphanesidir.
- Matlab Neural Network Toolbox, yapay sinir ağlarının tasarlanmasını, gerçekleştirilmesini, görselleştirilmesini ve simülasyonunu sağlayan, Matlab için geliştirilmiş bir araçtır.

Bu çalışmada, C#.NET programlama dili kullanılarak YSA'nın öğrenme, genelleme, özelliklerinin kolayca görülebileceği, tahmin ve sınıflandırma problemlerinin uygulanabileceği görsel ve esnek bir yazılım geliştirilmiştir. Yazılımda tek katmanlı algılayıcılardan adaline modeli ve çok katmanlı algılayıcı modeli geri yayılım algoritması kullanılarak tasarlanmıştır. Yazılımın çok katmanlı algılayıcı bölümünde, ağı yapısı, katman ve katmanlardaki nöron sayısı, verilerin normalizasyon yöntemi, katmanlarda kullanılan aktivasyon fonksiyonu, öğrenme oranı, momentum katsayısı, iterasyon sayısı, eğitimi sonlandırma koşulu, başlangıç ağırlıklarının seçimi kullanıcı tarafından belirlenmektedir. Eğitim esnasında oluşan hatanın grafiği gözlemlenebilmektedir. Test işleminden sonra ağı performansı ölçülebilmekte ve ayrıca sınıflandırma problemleri için karmaşıklık matrisi gözlemlenebilmektedir. Ağı yapısı, kullanılan parametreler, eğitim ve test verisi, eğitilen ağı bağlantı ağırlıkları, eşik değerleri ve test işleminden sonra ağı çıktıları, eğitim ve test işleminin hata ve süre değerleri bir klasör içerisinde (.txt) uzantılı dosyalar ile dizine kaydedilmektedir. Kaydedilen ağırlık ve eşik değerleri aynı ağ topolojisine sahip bir ağa başlangıç değerleri olarak verilip, eğitim ve test işlemi tamamlandığında başarımlar artırılabilir.

## 2. YÖNTEM: YAPAY SİNİR AĞLARI

Yapay sinir ağları (YSA), genel olarak insan beyninin ya da merkezi sinir sisteminin çalışma prensiplerini taklit eden bilgi işleme sistemidir [6]. Bu konu üzerindeki çalışmalar ilk olarak beyni oluşturan biyolojik üniteler olan nöronların modellenmesi ve bilgisayar sistemlerinde uygulanması ile başlamıştır. Nöronlar bağlantılarla birbirine bağlanır ve her bağlantı, girdisinin gücünü veya diğer bir deyişle önemini ifade eden sayısal bir ağırlığa sahiptir. Ağırlıklar, YSA 'lardaki uzun süreli belleğin temel aracıdır. Bir sinir ağı, bu ağırlıkların tekrar tekrar ayarlanması yoluyla öğrenme gerçekleştirir [7].


Yapay sinir ağının genelleme yeteneği ağı topolojisinin doğru seçilmesi ile birebir ilişkilidir. Ağ için en uygun mimari, problemi öğrenmek için yeterince büyük, genelleme yapabilmek için ise bir o kadar küçük olmalıdır. En uygun mimariden daha küçük bir ağ problemi iyi öğrenemez diğer taraftan daha büyük bir ağ ise eğitim verisini

aşırı öğrenir ki bu da ezberlemesine neden olduğundan genelleme yeteneği zayıf kalır. Ağın yapısının belirlenmesinde temel olarak büyüyen/yapıcı ve budama/yıkıcı olmak üzere iki açgözlü yaklaşım bulunmaktadır. Ağın yapısı küçük seçilip öğrenme sürecinde büyüyor ise büyüyen/yapıcı bir yaklaşım, aksine büyük seçilip öğrenme süresince küçülüyor ise budama/yıkıcı bir yaklaşım izlenmiştir [8].

YSA'lar genel olarak tek katmanlı algılayıcılar ve çok katmanlı algılayıcılar olarak ikiye ayrılmaktadır.

### 2.1. Tek Katmanlı Algılayıcılar

Tek katmanlı yapay sinir ağları doğrusal problemlerin çözümünde kullanılıp sadece girdi ve çıktı katmanından oluşmaktadır. Katmanların bir veya daha fazla nöronu bulunabilmektedir. Şekil 1'de basit bir tek katmanlı algılayıcı modeli gösterilmiştir.



Şekil 1. Tek Katmanlı Algılayıcı (TKA) Modeli

Eşik girdisi, bu tip ağlarda nöron elemanlarının değerlerinin ve de ağın çıktısının 0 olmasını önler. Değeri daima 1'dir. Ağın çıktısı Denklem 1'de gösterildiği gibi ağırlıklandırılmış girdi değerlerinin eşik değeri ile toplanması sonucu elde edilir.

$$\zeta = f\left(\sum_{i=1}^n w_i x_i + \phi\right) \quad (1)$$

Denklem 1'de  $x_i$ ,  $i = 1, 2, \dots, n$  ile ağın girdileri,  $w_i$ ,  $i = 1, 2, \dots, n$  ile bu girdilere karşılık gelen ağırlık değerleri,  $\phi$  ile eşik değeri gösterilmiştir. Tek katmanlı algılayıcıda çıktı fonksiyonu doğrusaldır. Böylelikle, ağa gösterilen örnekler eşik değer fonksiyonu ile iki sınıf arasında paylaştırılarak iki sınıfı birbirinden ayıran doğru bulunmaya çalışılır. Ağın çıktısı 1 veya -1 değeri alır. Eşik değer fonksiyonu Denklem 2' de gösterilmiştir.

$$f(g) = \begin{cases} 1, & \zeta > 0 \\ -1, & \zeta \leq 0 \end{cases} \quad (2)$$

Sınıf ayırıcı doğrusu Denklem 3'teki gibi tanımlanmaktadır.


$$W_1 X_1 + W_2 X_2 + \phi = 0 \quad (3)$$

Buradan;

$$X_1 = -\frac{W_2}{W_1} X_2 - \frac{\phi}{W_1} \quad (4)$$

$$X_2 = -\frac{W_1}{W_2}X_1 - \frac{\phi}{W_2} \quad (5)$$

olarak elde edilir. Denklem 4 ve 5 kullanılarak Şekil 2’ de geometrik gösterimi verilen sınıf ayırıcı doğrusu çizilebilmektedir.



Şekil 2. Sınıf Ayırıcı Doğrusu

Ağırlık değerleri, sınıf ayırıcı doğrusunun her iki grubu en iyi ayırarak şekilde belirlenmesi için her iterasyonda Denklem 6’daki formül ile değiştirilir.

$$W_i(t+1) = W_i(t) + \Delta W_i(t) \quad (6)$$

Eşik değeri de sınıf ayırıcı doğrusunu sınıflar arasında kaydırmak için her iterasyonda Denklem 7’deki formül ile güncellenir.

$$\phi(t+1) = \phi(t) + \Delta \phi(t) \quad (7)$$

Tek katmanlı algılayıcılarda başlıca iki modelden söz edilebilir. Bunlar;

- Perceptron Modeli
- Adaline/Madaline Modeli

dir [9].

### 2.1.1. Basit Algılayıcı Modeli (Perceptron)

1958 yılında psikolog Frank Rosenblatt tarafından “zeki sistemlerin temel özelliklerinden bazılarını simüle etmek” amacıyla geliştirilen perceptron modeli, bir sinir hücresinin birden fazla girdiyi alarak bir çıktı üretmesi prensibine dayanır. Ağın çıktısı, girdi değerlerinin ağırlıklı toplamının bir eşik değeri ile karşılaştırılması sonucu elde edilir. Toplam eşikten eşit veya büyük ise çıktı değeri 1, küçük ise 0 seçilir. Rosenblatt, algılayıcı eğitimi için desen tanıma problemlerini çözen bir öğrenme kuralı geliştirdi [10]. Bu kuralın, eğer problemi çözen ağırlıklar varsa, daima doğru ağırlıklara yakınsayacağını kanıtladı. Marvin Minsky ve Seymour Papert algılayıcılar üzerinde yaptıkları derin matematiksel incelemeler sonucunda, algılayıcıların çok sınırlı alanlarda kullanılabileceğini ve



algılayıcının çözemeyeceği çok fazla problem sınıfı olduğunu yayınladıkları "Perceptrons" kitabıyla kamuya göstermişlerdir [11]. Algılayıcıların çözemediği problemlere örnek olarak XOR problemini gösterebiliriz. Algılayıcıların bu sınırlaması 1980'lere gelindiğinde çok katmanlı perceptron modelinin geliştirilmesi ile giderilmiştir.

### 2.1.2 Adaline Modeli

Bernard Widrow, 1950'lerin sonlarında, Frank Rosenblatt'ın perceptronu geliştirdiği sırada, sinir ağları üzerine çalışmaya başlamıştır. 1960 yılında Widrow ve onun lisansüstü öğrencisi Marcian Hoff, ADALINE ağı ile En Küçük Kareler (Least Mean Square) algoritması olarak adlandırılan bir öğrenme kuralı geliştirdiler. Açık adı 'ADaptive LInear NEuron' veya 'ADaptive LInear Element' olan bu sinir hücresi modeli yapısal olarak algılayıcıdan farklı değildir. Ancak, algılayıcı aktivasyon fonksiyonu olarak eşik fonksiyonu kullanırken ADALINE doğrusal fonksiyon kullanır. Her iki modelde yalnızca doğrusal olarak ayrılabilen problemlere çözüm üretebilmektedir.


Widrow-Hoff kuralı da denilen En Küçük Kareler algoritması, perceptronun öğrenme kuralından daha güçlüdür. Perceptron öğrenme kuralı bir çözüme yakınsamayı garanti etse dahi, eğitim kalıplarının sınır çizgisine yakınlığından dolayı gürültüye duyarlı olabilir. En küçük kareler algoritması, ortalama karesel hatayı minimize ettiğinden eğitim kalıplarını sınır çizgisinden olabildiğince uzak tutmaya çalışır.

Widrow ve Hoff, birden fazla adaptif eleman içeren MADALINE yapay sinir ağı modelini de geliştirdiler.

### 2.2. Çok Katmanlı Algılayıcılar

Tek katmanlı algılayıcıların doğrusal olmayan problemlerin çözümünde başarısız olmasının üzerine geliştirilen çok katmanlı algılayıcılar (ÇKA), bilgi girişinin yapıldığı girdi katmanı, bir veya daha fazla gizli (ara) katman ve bir çıktı katmanından oluşmaktadır. ÇKA'da katmanlar arası ileri ve geri yayılım olarak adlandırılan geçişler bulunur. İleri yayılım safhasında, ağırlık çıkışı ve hata değeri hesaplanır. Geri yayılım safhasında ise hesaplanan hata değerinin minimize edilmesi için katmanlar arası bağlantı ağırlık değerleri güncellenir.

Şekil 3'te ÇKA yapısı gösterilmiştir.



Şekil 3. ÇKA Modeli

ÇKA modeli doğrusal perceptrondaki en küçük kareler algoritmasının genelleştirilmesi olan geri yayılım (backpropagation) öğrenme algoritmasını kullanır.

#### Geri Yayılım Algoritması

Geri yayılım (backpropagation), algoritması, ağırlık çıkışının belirlendiği ileri besleme ve oluşan hatanın gradiyenti azaltacak şekilde geri yayılarak ağırlıkların güncellendiği geri besleme safhalarından oluşmaktadır.

İleri besleme safhasında, eğitim setinin girdileri ağırlık giriş katmanına sunulur. Giriş katmanı, bu girdileri alan nöronları içerir. Bu sebeple giriş katmanındaki nöron sayısının veri setindeki girdi değeri sayısı ile aynı olması gerekir. Giriş katmanındaki nöronlar girdi değerlerini doğrudan gizli katmana iletir. Gizli katmandaki her bir nöron, ağırlıklandırılmış girdi değerlerine eşik değeri de ekleyerek toplam değeri hesap eder ve bunları bir

aktivasyon fonksiyonu ile işleyerek bir sonraki katmana veya doğrudan çıkış katmanına iletir. Katmanlar arasındaki ağırlıklar başlangıçta genellikle rasgele seçilir.

Çıkış katmanındaki, her bir nöronun net girdisi, ağırlıklandırılmış girdi değerlerine eşik değerin eklenmesiyle hesaplandıktan sonra, bu değer yine aktivasyon fonksiyonu ile işlenerek çıktı değerleri belirlenir. Ağın çıktı değerleri beklenen çıktı değerleri ile karşılaştırılarak hata değeri hesaplanır. Bu sebeple, çıkış katmanında bulunacak nöronların sayısı veri setindeki çıktı sayısı ile örtüşmelidir.

$j$ . çıktı hücresi için  $n$  'inci eğitim verisi sonrası,  $d_j(n)$  beklenen değer olmak üzere hata şu şekilde tanımlanır;

$$e_j(n) = d_j(n) - y_j(n) \quad (8)$$

Çıktı katmanındaki toplam hata Denklem 9 ile ifade edilir.

$$E(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (9)$$

$C$  kümesi çıktı katmanındaki tüm nöronları içermektedir. Burada delta kuralındakine benzer bir yaklaşımla  $E(n)$  en düşük hale getirilmeye çalışılır. Çıktı katman hücresine gelen girdiler toplamı Denklem 10 ile ifade edilir.

$$v_j(n) = \sum_{i=0}^m w_{ji}(n)x_i(n) \quad (10)$$

$X=(x_1, \dots, x_n)$ ,  $j$ . nörona uygulanan  $m$  girdi değerini,  $w_j$ ,  $x_i$  girdisinin ağırlığını ve  $f$  aktivasyon fonksiyonunu göstermektedir.  $w_{j0}$  sapma elemanını gösterir ve böylece  $x_0 = +1$  olur.

Ağın çıktı hücrelerinin ürettiği sonuç Denklem 11'deki formül ile hesaplanır.

$$y_j(n) = f(v_j(n)) \quad (11)$$

Ağın gradyeni hata fonksiyonunun ağırlıklara göre türevi alınarak bulunabilir. Zincir kuralına göre, gradyen aşağıdaki şekilde ifade edilebilir:

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)}$$

Tek tek türevler alınır,

$$\frac{\partial E(n)}{\partial W_{ji}(n)} = -e_j(n) f(v_j(n)) x_i(n) \quad (12)$$

Ağırlık düzeltme miktarı,  $\Delta W_{ji}(n)$  delta kuralına göre uygulanır.

$$\Delta W_{ji}(n) = -\eta \frac{\partial E(n)}{\partial W_{ji}(n)} \quad (13)$$

$\eta$  öğrenme oranıdır. Denklem 13 'deki  $-$  işareti ağırlık uzayındaki dik inişi temsil eder. Böylece geriye yayılma algoritması için ağırlık düzeltme miktarı, Denklem 14' deki gibi ifade edilir.

$$\Delta W_{ji}(n) = \eta \delta_j(n) x_i(n) \quad (14)$$

Yerel gradyen  $\delta_j(n)$  ise şöyle tanımlanır.

$$\delta_j(n) = e_j(n) f'(v_j(n)) \quad (15)$$

Gizli katmanda bulunan herhangi bir  $j$  nöronu için, çıkış katmanındaki nöronlar gibi istenen çıktı değeri belirtilmemiştir. Bu nedende gizli bir  $j$  nöronunun hata değeri, o nöronun direk bağlı olduğu tüm nöronların hata değerinden geri dönük olarak etkilenecektir. Gizli katmandaki herhangi bir  $j$  nöronu için, yerel gradyen  $\delta_j(n)$  şu şekilde tanımlanır.

$$\delta_j(n) = f'(v_j(n)) \sum_{j=0}^l \delta_j(n) w_{ji}(n) \quad (16)$$

1986 yılında Rumelhart, geriye yayılım algoritmasının ağırlık güncelleme denklemine,  $\alpha$  momentum terimi ekleyerek, ağırlık yerel minimuma takılması olasılığını azaltmıştır. Momentum terimi eklendikten sonra ağırlık güncelleme denklemi aşağıdaki hali alır.

$$w_{ji}(n+1) = w_{ji}(n) + \Delta w_{ji}(n) \quad (17)$$

$$\Delta w_{ji}(n) = \eta \delta_j(n) x_i(n) + \alpha \Delta w_{ji}(n) \quad (18)$$

Geri yayılım algoritmasında eğitim setinin hesaplamaya dahil edilmesinde kullanılan iki öğrenme yöntemi vardır. Bu yöntemler tekil (online) eğitim ve toplu (batch) eğitim. Tekil eğitimde ağırlıkların güncelleştirilmesi işlemi eğitim veri setindeki her bir örnek ağırlık uygulandığında oluşan hatanın geri yayılımı ile gerçekleştirilir. Toplu eğitimde ise eğitim veri setinin tamamı ağırlık uygulandıktan sonra elde edilen ortalama hatanın geri yayılımı ile ağırlıkların güncelleştirilmesi yapılır. Toplu eğitim paralelleştirilebilirken, tekil eğitim paralelleştirilememektedir [12].

Eğitim sürelerini azaltmak için sezgisel yaklaşım yöntemleri kullanılmaktadır. Geri yayılım algoritmasında yakınsamayı hızlandırmak ve ağırlık performansını iyileştirecek birkaç teknikten biri olan sezgisel yaklaşım teknikleri momentum katsayısı kullanılarak yapılır. Momentum katsayısı YSA'nın daha hızlı toparlanmasına

yardım eden bir faktördür. Temel olarak daha önceki değişimin bir kısmını işlem gören değişime eklemeye dayanır. Momentum katsayısı ağırlık yerel gradientleri aşmasını sağladığı gibi aynı zamanda hatanın düşmesine de yardımcı olur [13].


Öğrenme oranı ( $\eta$ ), bir öğrenme prosedürünün hızı ve doğruluğu ile orantılı olup bunları kontrol eden bir sabittir. Öğrenme oranı, YSA'nın ağırlıklarının değişiminde kullanılmaktadır. Öğrenme oranı çok büyük seçilirse hata yüzeyinde geniş atlamalar meydana gelir, öğrenmenin gerçekleşeceği dar alanlar atlanabilir. Ayrıca, hata yüzeyi boyunca hareketler çok kontrolsüz olur. Çok küçük seçilmesi durumunda ise öğrenme süresi çok zaman alabilir. Tecrübeler  $0.01 \leq \eta \leq 0.9$  aralığında seçilen öğrenme oranını iyi sonuçlar verdiğini göstermektedir. Büyük bir öğrenme oranı, başlangıçta iyi sonuçlara yol açar, ancak daha sonra yanlış sonuçlar verebilir. Daha küçük bir öğrenme oranı ile ise öğrenme daha zaman alıcıdır, ancak sonuç daha nettir. Böylece, öğrenme sürecinde öğrenme oranının başlangıçta büyük seçilerek zamanla (her iterasyonda veya birkaç iterasyonda bir) azaltılması gerekir [14].

Öğrenme oranının zaman içerisinde azaltılması çürüme (decay) olarak adlandırılır.

### 3. BULGULAR: GELİŞTİRİLEN ARAYÜZÜN İNCELENMESİ

YSA 'lar tahmin, sınıflandırma, modelleme gibi birçok günlük hayat probleminin çözümünde kullanılan bir yaklaşımdır. Geliştirilen yazılımda tek katmanlı algılayıcılardan Adaline modeli, çok katmanlı algılayıcılar için geri yayılım algoritması ile birçok alandan tahmin ve sınıflandırma problemlerinin çözümü için YSA yapılabilecek esnek ve görsel bir arayüz tasarlanmıştır. Ayrıca yazılımda tek değişkenli ve iki değişkenli fonksiyonlar ile YSA'nın sınıflandırma kısmında kullanılmak üzere veri kümesi üretilebilecek bir arayüz de mevcuttur.

Şekil 4'de tasarlanan yazılımın giriş ekranı gösterilmiştir. Ekranın sol alt bölümünde bulunan menüden istenilen arayüze ulaşılabilir. İstenilen arayüze çift tıkladıktan sonra, arayüz menünün sağına gömülürken, o bölümde yapabileceğimiz işlemler ile ilgili butonların bulunduğu panel ekranın üstünde konumlanmaktadır.

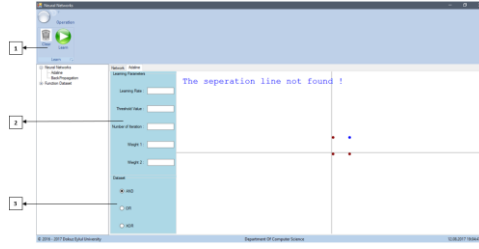


Şekil 4. Geliştirilen Arayüzün Giriş Ekranı

Bilindiği gibi tek katmanlı algılayıcılar ile doğrusal olarak ayrılabilen problemlerin çözümünde başarılı sonuçlar elde edilmektedir. Tasarlanan arayüzde mantıksal AND ve OR operatörünün adaline modeli ile doğrusal olarak ayrılabilen gözlemlenebilirken, doğrusal olarak tek bir doğru ile ayrılamayan mantıksal XOR operatörüne çözüm üretmediği gözlemlenmektedir. Ayrıca kullanıcı ekrandan mouse'un sağ ve sol tuşunu kullanarak iki farklı sınıftan noktalar ekleyebilir ve iki sınıfın doğrusal olarak tek bir doğru ile ayrılıp ayrılamayacağını gözlemleyebilir.

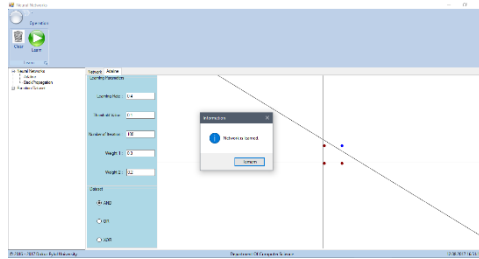
Şekil 5'te menüden Adaline'a tıklandığında karşılaşılan ekran görüntüsü gösterilmiştir. Şekilde numaralandırılan bölümlerin yaptığı işlemler şu şekilde sıralanabilir.

1. Ekranı temizlemeye yarayan "Clear" butonu ile öğrenme işlemi başlatan "Learn" butonunun bulunduğu paneldir.
2. Eğitimde kullanılacak öğrenme oranı, eşik değeri, iterasyon sayısı ve başlangıç ağırlık değerleri girildiği paneldir.
3. Veri setinin seçileceği paneldir.



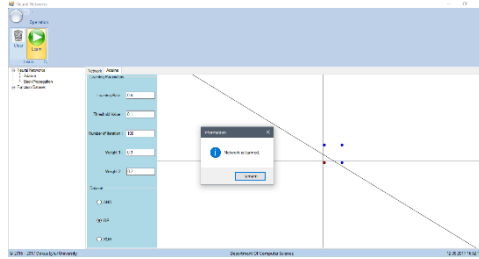
Şekil 5. Adaline Arayüzü

Şekil 6’da öğrenme oranı 0.4, eşik değeri 0.1, iterasyon sayısı 100, başlangıç ağırlıkları 0.3 ve 0.2 seçilerek eğitimi tamamlanmış mantıksal AND operatörü gösterilmiştir.



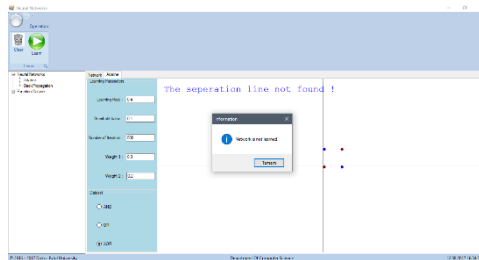
Şekil 6. Adaline Modeli ile Eğitilen AND Operatörü

Şekil 7’de öğrenme oranı 0.4, eşik değeri 0.1, iterasyon sayısı 100, başlangıç ağırlıkları 0.3 ve 0.2 seçilerek eğitimi tamamlanmış mantıksal OR operatörü gösterilmiştir.




Şekil 7. Adaline Modeli ile Eğitilen OR Operatörü

Şekil 8’de ise öğrenme oranı 0.4, eşik değeri 0.1, iterasyon sayısı 500, başlangıç ağırlıkları 0.3 ve 0.2 seçilerek eğitilen fakat 500 iterasyon tamamlanmasına rağmen doğrusal olarak ayrıştırılamayan mantıksal XOR operatörü gösterilmiştir.



Şekil 8. Adaline Modeli ile Eğitilemeyen XOR Operatörü

Şekil 9'da ise mouse'un sağ ve sol tuşları ile eklenen noktaların, öğrenme oranı 0.4, eşik değeri 0.1, iterasyon sayısı 100, başlangıç ağırlıkları 0.3 ve 0.2 seçilerek iki farklı sınıfa ayıran doğru Adaline ağı ile eğitilen ağı çizilmiştir.



Şekil 9. Adaline Modeli ile Eğitilen iki farklı noktalar kümesi

Adaline sekmesi kapatılırken ekrandaki eğitim parametrelerini ve seçili veri setini (.ini) uzantılı dosyasına kaydeder. Bir sonraki çalıştırmada kaydedilen parametrelerle Adaline ekranı açılmaktadır.

### Yazılımda Geliştirilen Backpropagation Arayüzü

Geliştirilen yazılım ile birçok alanda karşılaşılan tahmin ve sınıflandırma problemleri için YSA tanımlanabilmektedir.

Yazılımda çok katmanlı algılayıcılar için geri yayılım algoritması kullanılmıştır. Geri yayılım algoritmasının öğrenme kuralı genelleştirilmiş delta kuralı da denilen gradiyent azaltma öğrenme algoritmasıdır. Yazılımda momentum ile gradiyent azaltma öğrenme algoritması (gradient descent with momentum) kullanılmıştır.

Yazılımda verilerin işlenmesinde doğrusal (lineer), max-min ve z-score normalizasyon yöntemleri kullanılmıştır.

#### Lineer Normalizasyon

Bir veri setindeki verilerin en büyük değere bölünerek normalleştirilmesi işlemidir. Bu işlem sonucunda veriler [0,1] aralığında yer almaktadır.

Matematiksel olarak ifade edilmek istenirse  $x_1, x_2, \dots, x_n$ ,  $n$  adet veriyi gösterebilir.  $X_{\max}$  ( $\max = 1, 2, \dots, n$ ) veri setindeki en büyük değer,  $x_{\text{normal}_i}$ ;  $x_i$  ( $i = 1, 2, \dots, n$ )'nin normalize edilmiş hali olsun. O halde,

$$x_{\text{normal}_i} = \frac{x_i}{X_{\max}} \quad (19)$$

olarak tanımlanmaktadır.

#### Max-Min Normalizasyon

Bu yöntemde, bir grup verinin içerisindeki en büyük ve en küçük değerler ele alınır. Diğer bütün veriler, bu değerlere göre normalleştirilir. Buradaki amaç en küçük değeri 0 ve en büyük değeri 1 olacak şekilde normalleştirmek ve diğer bütün verileri bu 0-1 aralığına yaymaktır.

Matematiksel olarak ifade edilmek istenirse

$x_1, x_2, \dots, x_n$ ,  $n$  adet veriyi gösterebilir.  $x_{\max}$  ( $\max = 1, 2, \dots, n$ ) veri setindeki en büyük değer,  $x_{\min}$  ( $\min = 1, 2, \dots, n$ ) veri setindeki en küçük değer,  $x_{\text{normal}_i}$ ;  $x_i$  ( $i = 1, 2, \dots, n$ )'nin normalize edilmiş hali ise Denklem 20 ile hesaplanmaktadır.

$$x_{\text{normal}_i} = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (20)$$

### Z-Score Normalizasyon

Bu yöntemde ise ortalama değer (mean value) ve standart sapma (standard deviation) değerleri göz önüne alınır. Matematiksel olarak ifade edilmek istenirse;

$x_1, x_2, \dots, x_n$ , n adet veriyi gösterebilir.

$\bar{x}$ : n adet verinin ortalaması

$\sigma$ : n adet verinin standart sapması

$x_{normal_i}$ ;  $x_i$  ( $i = 1, 2, \dots, n$ )'nin normalize edilmiş hali ise Denklem 21 'daki formül ile elde edilir.

$$x_{normal_i} = \frac{x_i - \bar{x}}{\sigma} \quad (21)$$

Çoklu sınıflandırma problemlerinde veriler normalleştirilirken çıktı değerleri sınıf sayısı boyutunda vektör ile temsil edilir. Vektörde verinin ait olduğu sınıf **1** diğerleri **0** olarak belirlenir. Örneğin, **5** sınıflı bir veri de **3**. Sınıfa ait verinin çıktı değerinin normalize edilmiş hali **[0, 0, 1, 0, 0]** vektörü ile gösterilmektedir.

Geliştirilen yazılımda doğrusal(lineer), sigmoid, rasyonel sigmoid, Gaussian ve tanjant hiperbolik aktivasyon fonksiyonları kullanılabilir. Kullanılan aktivasyon fonksiyonlarının matematiksel ifadeleri Tablo 1'de gösterilmiştir.

**Tablo 1.** Yazılımda kullanılan aktivasyon fonksiyonları

Fonksiyonun Adı	Formülü
Lineer	$y = x$
Sigmoid	$y = \frac{1}{1 + e^{-x}}$
Rasyonel Sigmoid	$y = \frac{x}{1 + \sqrt{1 + x^2}}$
Gaussian	$y = e^{-x^2}$
Tanjant Hiperbolik	$y = \frac{1 - e^{-2x}}{1 + e^{-2x}}$

Yazılımda geri yayılım algoritması ile eğitim yapılırken öğrenme oranı ve momentum belirlenen çürüme oranı (s) ile her iterasyonda (o anki iterasyon sayısı (t) kullanılarak) çürütülebilir.

Bu işlemin matematiksel ifadesi öğrenme oranı ( $\eta$ ) ve momentum ( $\mu$ ) için sırasıyla Denklem 22 ve 23 'de gösterilmiştir.

$$\eta_{yeni} = \frac{\eta_{eski}}{(1+st)} \quad (22)$$

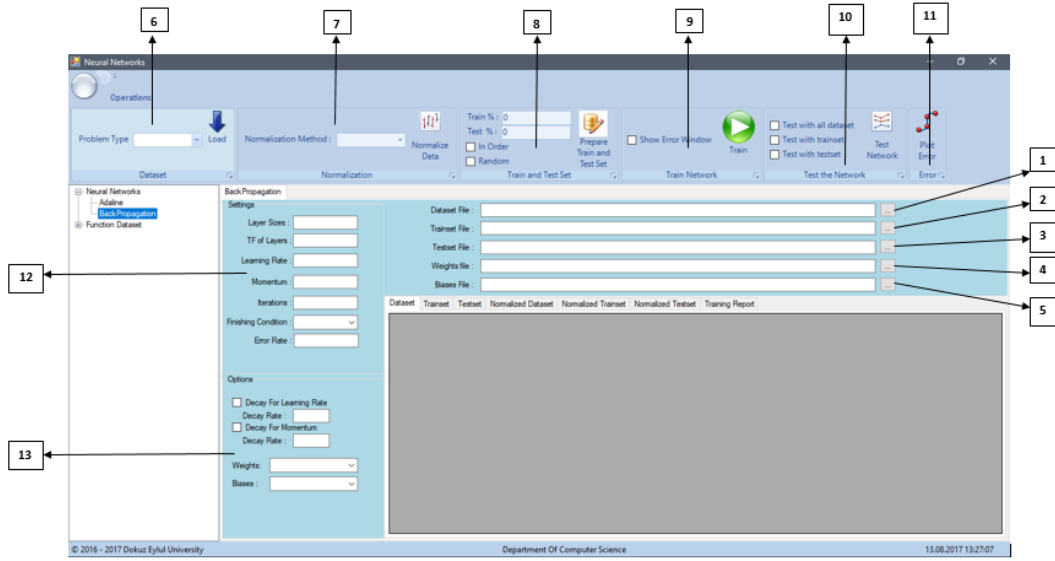
$$\mu_{yeni} = \frac{\mu_{eski}}{(1 + st)} \quad (23)$$

Yazılımda geliştirilen backpropagation arayüzünün tam ekran görüntüsü Şekil 10'da gösterilmiştir. Numaralandırılan alanların işlevleri şu şekilde sıralanabilir.

1. Veri setinin yükleneceği dosya konumunu açan butondur.
2. Tüm veri seti yerine eğitim ve test seti ayrı ayrı yükleneceği zaman eğitim setinin seçilmesi için dosya konumunu açan butondur
3. Tüm veri seti yerine eğitim ve test seti ayrı ayrı yükleneceği zaman test setinin seçilmesi için dosya konumunu açan butondur.
4. Başlangıçta katmanlardaki nöronlar arası bağlantı ağırlık değerleri dosyadan yüklenmek istendiğinde ilgili dosya konumunu açan butondur.
5. Girdi katmanı hariç katmanlardaki nöronların başlangıçtaki eşik değerleri dosyadan yüklenmek istendiğinde ilgili dosya konumunu açan butondur.
6. Uygulamanın yapılacağı problem tipinin seçilip verinin yüklendiği paneldir. Tahmin ve sınıflandırma olmak üzere iki tip problem seçimi yapılmaktadır. Tahmin problemleri için “Approximation”, sınıflandırma problemleri için “Pattern Recognition” seçilmelidir. “Load” butonuna tıklanarak verinin yüklenmesi sağlanmaktadır.
7. Doğrusal, max-min ve z-score olmak üzere 3 tip normalizasyon seçeneği mevcuttur.
8. Eğitim ve test seti yüzdeleri belirlendikten sonra, eğitim ve test setinin sırayla veya rastgele oluşturulması tercihi yapılarak “Prepare Train and Test Set” butonuna tıklanıldığında eğitim ve test seti hazırlanmaktadır.
9. Ağın eğitiminin yapılacağı paneldir. Bu alan kullanılmadan önce 12 ve 13 ile numaralandırılmış alanlardaki ağın eğitim parametrelerinin girilmiş olması gerekmektedir. Bu alanda ağın eğitimi esnasında hatanın grafiğinin görüntülenmek istenip istenmediği seçimi yapılarak “Train” butonuna tıklanıp ağın eğitimi başlatılır.
10. Ağın test işleminin gerçekleştirildiği paneldir. Test işleminde kullanılacak veriseti seçimi yapıldıktan sonra “Test the Network” butonuna tıklanarak test işlemi başlatılır.
11. Eğitilen ağın hata grafiğinin görüntülenmesi için tıklanacak olan butonu barındıran paneldir.
12. YSA'nın eğitim işlemi tamamlanmadan önce ağın parametrelerinin belirlendiği paneldir. Bu parametreler;
  - Ağda kullanılacak katmanların ve bu katmanlardaki nöron sayılarının belirlenmesi. Katmanlardaki nöron sayıları aralarında birer boşluk bırakılarak “Layer Sizes” kutucuğuna girilmelidir. Birden fazla gizli katman eklenebilir. Örneğin “Layer Sizes” kutucuğuna girilen değer “2 3 4 1” ise, ilk değer girdi katmanı, son değer çıktı katmanı ve aradaki değerler gizli katmanlardaki nöron sayılarını ifade eder. Bu örnekte; 2 nörona sahip girdi katmanı, 3 nörona sahip birinci gizli katman, 4 nörona sahip ikinci gizli katman ve 1 nörona sahip çıkış katmanı bulunmaktadır. Çıktı değerlerine göre program sınıf sayısını belirlemektedir.
  - Katmanlarda kullanılacak aktivasyon fonksiyonları belirlenmelidir. Linear, Sigmoid, Rasyonel Sigmoid, Gaussian ve Tanjant Hiperbolik aktivasyon fonksiyonları seçilebilmektedir. Katmanlarda kullanılmak istenen aktivasyon fonksiyonları baş harfleri ile aralarında birer boşluk kullanılarak “TF’s of Layers” kutucuğuna girilmelidir. Girdi katmanında aktivasyon fonksiyonundan geçmeden direk gizli katmana iletildiği için girdi katmanı için N (none) harfi girilmelidir.
  - Ağın eğitilmesinde kullanılacak olan öğrenme oranının belirlenmesi. **0** ile **1** arasında olması önerilir.
  - Ağın eğitilmesinde kullanılacak olan momentum katsayısının belirlenmesi. **0** ile **1** arasında olması önerilir.
  - Ağın eğitiminde kullanılacak olan azami iterasyon sayısının belirlenmesi.
  - Eğitimi bitirme koşulunun belirlenmesi. Ağın eğitimi azami iterasyon sayısına ulaşıldığında, indirgenilmek istenilen minimum hata değerine ulaşıldığında ve azami iterasyon sayısı veya minimum hata değerinden biri sağlandığında durdurulmaktadır.
  - Ağın hatasının indirgenmek istenildiği minimum hata değerinin belirlenmesi.
13. Ağ eğitilirken öğrenme oranı veya momentum için çürüme (decay) yapılıp yapılmayacağını ve eğer yapılacaksa oranının belirlendiği paneldir. Bu panelde ayrıca ağın eğitiminde kullanılacak başlangıç



ağırlıkları ve eşik değerlerinin seçimi belirlenir. Bu seçimde ağırlıklar ve eşik değerleri (-1,1), (-0.5,0.5), (0,1) aralıklarında rastgele, normal dağılım gösteren veya dosyadan okutulabilir.



Şekil 10. Geliştirilen Backpropagation Arayüzü

Geliştirilen yazılımda sınıflandırma problemleri için doğruluk (accuracy), duyarlılık (sensitivity) ve özgülük (specificity) değeri sırasıyla Denklem 24, 25 ve 26 ' da verilen formülle hesaplanmaktadır.

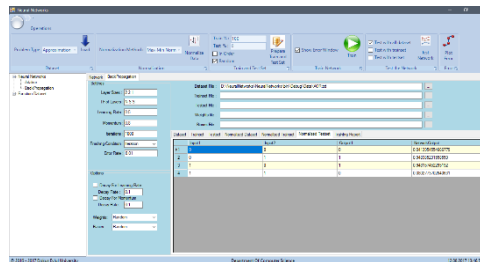
$$\text{Doğruluk} = \frac{DP+DN}{DP+YN+YP+DN} \quad (24)$$

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (25)$$

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (26)$$


**DP:** Doğru Pozitif  
**DN:** Doğru Negatif  
**YP:** Yanlış Pozitif  
**YN:** Yanlış Negatif

Şekil 11'de XOR mantıksal operatörünün geri yayılım algoritması ile eğitilmesi sonucunda elde edilen ekran görüntüsü verilmiştir. Eğitim setiyle test edilen ağırlıkların görüldüğü gibi gerçek çıktı ile arasındaki farkın (hata) yeterince küçük olduğu gözlenmektedir. Bu örnek ile ÇKA'nın doğrusal olmayan XOR operatörüne çözüm üretebildiği görülmektedir.



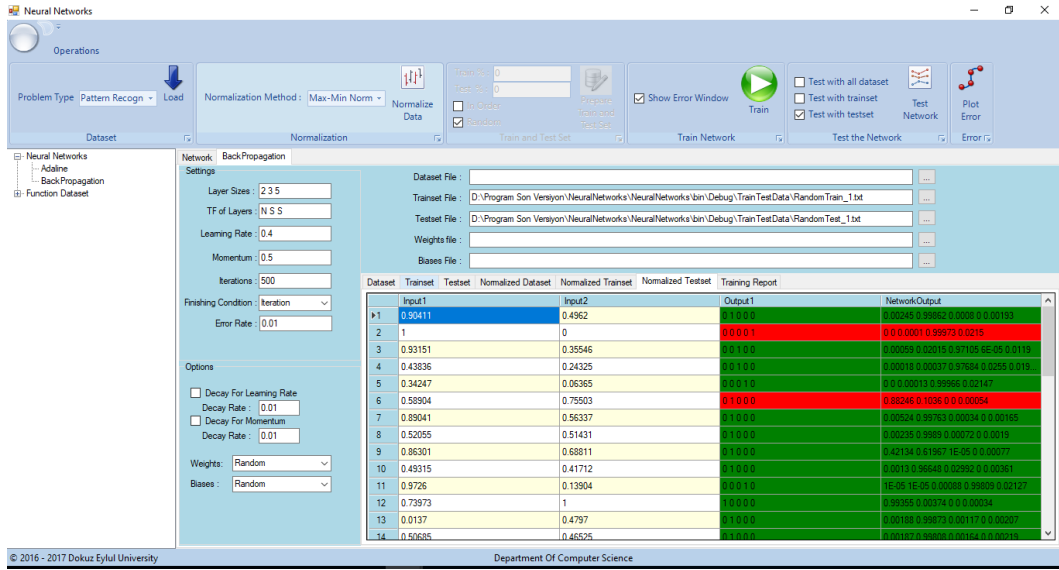
Şekil 11. XOR operatörünün ÇKA ile çözümü

Şekil 12’de eğitilen XOR operatörünün eğitim esnasındaki hata değerinin iterasyon sayısına göre grafiği gösterilmiştir.




Şekil 12. XOR operatörünün hata grafiği

[-10,10] aralığında ele alınan xsinx fonksiyonun değer kümesinin 5 farklı sınıfa ayrılarak elde edilen sınıflandırma problemi için başlangıç ağırlıkları rastgele seçilen ağ, giriş katmanında 2 nöron, gizli katmanda 3 nöron ve çıktı katmanında 5 nöron (sınıf sayısı) ve gizli ve çıktı katmanlarında sigmoid aktivasyon fonksiyonu kullanılıp, öğrenme oranı 0.4, momentum katsayısı 0.5, iterasyon sayısı 500 seçilerek eğitilmiş ve daha önce hiç karşılaşmadığı test kümesi örnekleri ile test edilmiştir. Test edildikten sonra karşılaşılan ekran görüntüsü Şekil 13’te gösterilmiştir. 201 örnekten oluşan veri seti 158 örnek ile eğitilmiş, kalan 43 örnek ile test edilmiştir.



Şekil 13. Sınıflandırma Problemi Örneği

Ağ test edildikten sonra doğru sınıflandırılan örnekler yeşil, yanlış sınıflandırılan örnekler kırmızı ile renklendirilmiştir. Eğitim sırasında oluşan hatanın iterasyon sayısına göre değişim grafiği Şekil 14’te gösterilmiştir.



Şekil 14. Sınıflandırma örneğinin hata grafiği

Ağın hiç karşılaşmadığı 43 adet test seti ile test edildikten sonra oluşan karmaşıklık matrisi Şekil 15’te verilmiştir. Karmaşıklık matrisinin satırları gerçek sınıfları, sütunları ise tahmini sınıf değerlerini göstermektedir. Sınıfların duyarlılık değerleri son sütunda gösterilirken özgüllük değerleri son satırda gösterilmiştir. Matrisin son satırı ve sütununun kesiştiği hücrede doğruluk oranı gösterilmiştir. Doğruluk oranı ayrıca matrisin üzerinde de belirtilmiştir.

Confusion						
Accuracy is % 93.0232558139535						
Rows : Actual Classes			Columns : Predicted Classes			
	PredictedClass1	PredictedClass2	PredictedClass3	PredictedClass4	PredictedClass5	Sensitivity
1	8	0	0	0	0	1
2	2	17	0	0	0	0.89
3	0	0	7	0	0	1
4	0	0	0	8	0	1
5	0	0	0	1	0	0
6	0.8	1	1	0.89	NaN	0.93

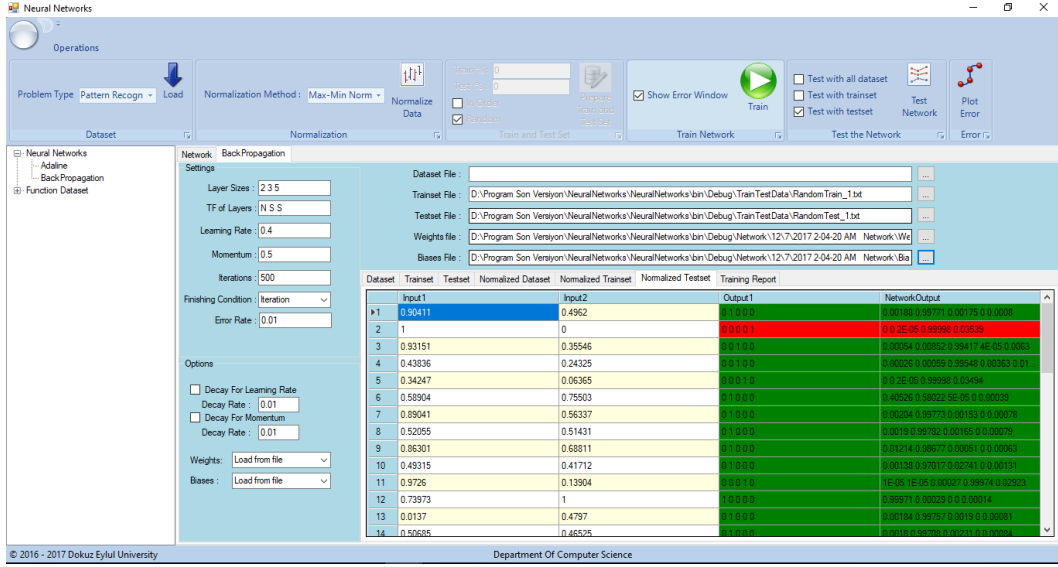
Şekil 15. Rastgele Ağırlıklarla Eğitilip Test Seti ile Test edilen Sınıflandırma Örneğinin Karmaşıklık Matrisi

Aynı ağın 158 örnekten oluşan eğitim seti ile test edilmesi sonucu oluşan karmaşıklık matrisi Şekil 16’da gösterilmiştir.

Confusion						
Accuracy is % 96.2025316455696						
Rows : Actual Classes			Columns : Predicted Classes			
	PredictedClass1	PredictedClass2	PredictedClass3	PredictedClass4	PredictedClass5	Sensitivity
1	28	0	0	0	0	1
2	1	71	0	0	0	0.99
3	0	2	21	2	0	0.84
4	0	0	0	32	0	1
5	0	0	0	1	0	0
6	0.97	0.97	1	0.91	NaN	0.96

Şekil 16. Rastgele Ağırlıklarla Eğitilip Eğitim Seti ile Test Edilen Sınıflandırma Örneğinin Karmaşıklık Matrisi

Ağ aynı parametreler ile yine aynı eğitim seti kullanılarak, başlangıç ağırlıkları ve eşik değerleri Şekil 17’de gösterildiği gibi bir önceki eğitimde elde edilen ağırlık ve eşik değerleri dosyadan seçilerek eğitilmiştir.



Şekil 17. Öğrendiği Ağırlıklarla Eğitilip Test edilen Sınıflandırma Örneği

Öğrendiği ağırlıklar ve eşik değerleri ile eğitilip test edilen ağırlık karmaşıklık matrisi Şekil 18’de gösterilmiştir.

The screenshot shows a confusion matrix with the following data:

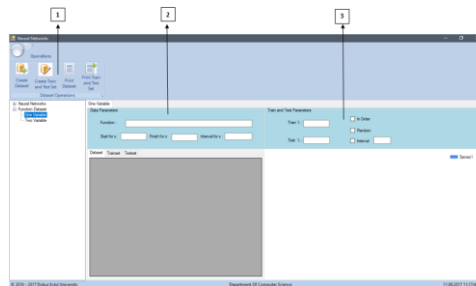
Accuracy is % 97.6744186046512						
Rows : Actual Classes		Columns : Predicted Classes				
	PredictedClass1	PredictedClass2	PredictedClass3	PredictedClass4	PredictedClass5	Sensitivity
1	8	0	0	0	0	1
2	0	19	0	0	0	1
3	0	0	7	0	0	1
4	0	0	0	8	0	1
5	0	0	0	1	0	0
6	1	1	1	0.89	NaN	0.98

Şekil 18. Öğrendiği Ağırlıklarla Eğitilen Sınıflandırma Örneğinin Karmaşıklık Matrisi

Şekil 18’de görüldüğü gibi öğrendiği ağırlıklar ile eğitilen ağ, başlangıç ağırlıkları rastgele seçilerek eğitilen ağa göre daha başarılı bir sonuç vermektedir. Burada bağlantı sayısının eşleşmesi için ağırlık topolojinin aynı seçilmesine dikkat edilmesi gerekmektedir.


### Tek Değişkenli ve İki Değişkenli Fonksiyonlar ile Veri Seti Oluşturulması

Yazılımın tek değişkenli ve iki değişkenli fonksiyon oluşturma arayüzlerine menüde “Function Dataset” “ine tıklandıktan sonra açılan “One Variable” ve “Two Variable” sekmelerine tıklanarak ulaşılabilmektedir. Tek değişkenli ve iki değişkenli fonksiyonların değer kümesinin sıfıra eşit, sıfırdan küçük ve sıfırdan büyük değerlerine göre 3 sınıfa ayrılarak veri seti oluşturulur. Şekil 19’da tek değişkenli fonksiyon oluşturmak için geliştirilen arayüz gösterilmiştir.



Şekil 19. Tek değişkenli fonksiyon arayüzü

Şekil 20’de iki değişkenli fonksiyon oluşturmak için geliştirilen arayüz gösterilmiştir



Şekil 20. İki değişkenli fonksiyon arayüzü

Numaralandırılmış alanların işlevleri şu şekildedir.

1. Veri setlerinin oluşturulması ve dosyaya yazılması için gerekli butonların bulunduğu paneldir. 2 ve 3 ile numaralandırılan alanlar doldurulduktan sonra kullanılır.
2. Fonksiyonun yazıldığı, başlangıç, bitiş ve arttırım aralığının belirlendiği paneldir. “Function” kutucuğuna fonksiyon yazılır, tek değişkenli fonksiyon için değişken değeri sadece “x” notasyonu ile iki değişkenli fonksiyonda ise değişkenler sadece “x” ve “y” notasyonları ile ifade edilip değişkenler parantez içerisinde yazılmalıdır. Değişkenlerin tanım kümesindeki başlangıç ve bitiş aralığı ile arttırım aralığı belirlenmektedir.
3. Oluşturulmak istenen eğitim ve test kümelerinin yüzdeleri belirlenerek, kümelerin oluşturulmasının sırayla, rastgele veya değişkenlerin belli aralıkta alınarak yapılması seçeneklerinden biri belirlenmektedir.

Geliştirilen yazılım C# ortamında ribbon form kullanarak tasarlanmıştır. Programın düzgün çalışabilmesi için kullanılan bilgisayarın ondalık ayracının nokta (.) olması gerekmektedir. Programda kullanılacak veri kümelerinin (.txt) formatında, her satırda bir örnek ve her örneğin giriş değerleri ve çıktı değeri aralarında birer boşluk bırakılarak sütunlarda yer alacak şekilde hazırlanmalıdır. Değişkenlerde başlık satırı bulunmamalıdır. Değişken sayılarında herhangi bir kısıtlama yoktur. Son sütun çıkış değerini göstermelidir. Sınıflandırma problemi içinde çıkış değerleri tek sütunda verilmelidir. Program kendi içerisinde sınıf sayılarını belirleyerek çıktı değerlerini vektör şeklinde normalleştirir. Veriler normalleştirilmiş şekilde yüklenir ise ondalıklı veriler için yine nokta kullanılmalı ve sınıflandırma problemlerinin çıktı sütunu normalleştirilmemiş şekilde girilmelidir.

#### 4. TARTIŞMA ve SONUÇ

Geliştirilen algoritmada backpropagation algoritması ile tahmin ve sınıflandırma problemlerine çözüm getirilmiştir. Arayüzün backpropagation bölümünde kullanıcıya sunulan imkanlar şöyle listelenebilir.

1. Geri yayılım algoritması ile doğrusal olmayan tahmin ve sınıflandırma problemlerine çözüm üretebilmektedir.
2. Çözülecek problem için veriler tüm veri seti veya eğitim ve test seti olarak ayrı ayrı yüklenebilmektedir. Yüklenen veriler (.txt) uzantılı dosyalara kaydedilir.
3. Veriler linear, max-min ve z-score (z-standartlaştırma) normalizasyon yöntemleri ile normalize edilebilmektedir.
4. Kullanıcı verileri normalize edilmiş şekilde de programa yükleyebilmektedir. Bu durumda normalizasyon bölümünde “None” ifadesi seçilmelidir. Normalize edilen eğitim ve test setleri (.txt) uzantılı dosyalara kaydedilir.
5. Eğer tüm veri seti yüklendi ise normalizasyon işleminin ardından eğitim ve test seti kullanıcının belirlediği yüzdeler ile sırayla veya rastgele oluşturulabilmektedir.
6. Kullanıcı birden fazla gizli katman ve bu katmanlarda istenildiği kadar nöron ekleyebilmektedir.

7. Katmanlarda linear, sigmoid, rasyonel sigmoid, Gaussian ve tanjant hiperbolik aktivasyon fonksiyonu kullanılabilir.
8. Ağın eğitilmesinde kullanılan başlangıç ağırlıkları ve eşik değerleri -1 ile 1 , -0.5 ile 0.5, 0 ile 1 arasında rastgele, normal dağılım gösteren (yani standart sapması 0 varyansı 1 olan) değerler ile başlayabildiği gibi kullanıcı tarafından (.txt) uzantılı dosyadan da girilebilir.
9. Eğitim sırasında momentum ve öğrenme oranı çürümesi (decay) yapılabilir.
10. Ağ eğitildiği esnada hata grafiği opsiyona göre eğitim sırasında veya sonrasında görülebilmektedir.
11. Ağ eğitimi tamamlandıktan sonra, test seti için Şekil 10 'nun 10.bölümünde gösterildiği gibi test işleminde kullanılacak olan veri seti opsiyonel olarak tüm veri seti, eğitim seti veya test seti olarak belirlenebilir. Sınıflandırma problemlerinde ağ test edildikten sonra karmaşıklık (confusion) matrisi, doğruluk, duyarlılık ve özgülük değerleri görülebilmektedir.
12. Veriler eğitildikten sonra ağın yapısı, kullanılan parametreler, son durumdaki bağlantı ağırlıkları ve eşik değerleri (.txt) uzantılı dosyalara kaydedilir. Kaydedilen bağlantı ağırlıkları ve eşik değerleri, aynı problem için aynı topolojiye sahip ağ ile tekrar eğitilmek istendiğinde başlangıç değerleri olarak seçilerek başarımın arttığı gözlemlenmektedir.
13. Test aşaması tamamlandıktan sonra test verisi için gerçek çıktı değerleri ile ağın ürettiği çıktı değerleri, hata ve süre değerleri, sınıflandırma problemleri için karmaşıklık matrisi doğruluk, duyarlılık ve özgülük değerleri (.txt) formatında dosyaya kaydedilmektedir.
14. Backpropagation arayüzü kapatılırken kullanılan parametre değerlere (.ini) dosyasına kaydedilir, ekran tekrar açıldığında kaydedilen son kaydedilen değerler ile birlikte arayüz açılmaktadır.

Yazılım nesne tabanlı yaklaşım ile geliştirildiğinden ileriki çalışmalar için geri yayılım algoritmasına farklı öğrenme fonksiyonları ve aktivasyon fonksiyonları kolaylıkla eklenebilir. ÇKA'da kullanılan farklı algoritmalar için arayüz oluşturulabilir.

Geliştirilen yazılım hali hazırda kullanılmakta olan birçok yapay sinir ağı kütüphanesine veya paket programlarının aksine ücretsiz olarak kullanıma sunulmuştur.

Bilimsel hesaplama paket programlarının içinden çağırılan yapay sinir ağı kütüphanelerini kullanabilmek için o paket programa ait notasyon bilgisine sahip olmak gerekmekte iken geliştirilen yazılımda tüm işlemler kullanıcı dostu arayüz ile gerçekleştirilmektedir.

Program Neural Networks linkinden indirilip kullanılabilir.

## KAYNAKLAR

- [1] A. S. Miller, B. H. Blott, and T. K. Hames, "Review of neural network applications in medical imaging and signal processing," *Med. Biol. Eng. Comput.*, vol. 30, no. 5, pp. 449–464, 1992.
- [2] R. Das, I. Turkoglu, and A. Sengur, "Expert Systems with Applications Effective diagnosis of heart disease through neural networks ensembles," *Expert Syst. Appl.*, vol. 36, no. 4, pp. 7675–7680, 2009.
- [3] M. A. Shahin, M. B. Jaks, and H. R. Maier, "Artificial Neural Network Applications in Geotechnical Engineering," *Aust. Geomech.*, vol. 36, no. 1, pp. 49–62, 2001.
- [4] P. D. McNelis, *Neural Networks in Finance: Gaining Predictive Edge in the Market*. Elsevier Inc., 2005.
- [5] A. C. Kınacı, "Görsel yazılım geliştirme ortamı ile beraber bir yapay sinir ağı kütüphanesi tasarımı ve gerçekleştirimi," Ege Üniversitesi, 2006.
- [6] J. A. Freeman and D. M. Skapura, *Neural Networks Algorithms, Applications and Programming Techniques*. New York, USA: Addison-Wesley Publishing Company, 1991.

- [7] M. Negnevitsky, *Artificial Intelligence: A Guide to Intelligent Systems*. Pearson Education, 2005.
- [8] O. ARAN, O. T. YILDIZ, and E. ALPAYDIN, “an Incremental Framework Based on Cross-Validation for Estimating the Architecture of a Multilayer Perceptron,” *Int. J. Pattern Recognit. Artif. Intell.*, vol. 23, no. 2, pp. 159–190, 2009.
- [9] E. Öztemel, *Yapay Sinir Ağları*. İstanbul: Papatya Yayıncılık Eğitim, 2012.
- [10] F. Rosenblatt, “The perceptron: A probabilistic model for information storage and organization in ...,” *Psychol. Rev.*, vol. 65, no. 6, pp. 386–408, 1958.
- [11] M. Minsky and S. Papert, *Perceptrons*. 1969.
- [12] S. Haykin, *Neural Networks and Learning Machines (Vol.3.)*, Pearson. Upper Saddle River, NJ, USA, 2009.
- [13] R. Bayındır and Ö. Sesveren, “Ysa Tabanlı Sistemler İçin Görsel Bir Arayüz Tasarımı,” *MÜHENDİSLİK BİLİMLERİ DERGİSİ*, vol. 14, no. 1, pp. 101–109, 2008.
- [14] D. Kriesel, *A Brief Introduction to Neural Networks*. 2007.

# Mobil Alışveriş Bağlamında Sürekli Kullanım Niyetinin İncelenmesi: İki Kuramsal Modelin Karşılaştırılması

Mehmet Cem Bölen, Üstün Özen, Ersin Karaman

## ÖZET

*Teknolojik alışkanlıkların çok hızlı değiştiği günümüzde teknoloji tabanlı bir ürün ya da hizmetin sürekli kullanımının sağlanması kuşkusuz en az benimsenmesi kadar önemlidir. Dolayısıyla son yıllarda teknoloji kabulü sonrası süreçte (post-adoption) yönelik çalışmaların sayısı gittikçe artmaktadır. Bu çalışmaların birçoğu Teknoloji Kabul Modeli (TKM) veya Bilgi Sistemleri Beklenti Onaylama Modelini (BSBOM) kuramsal altyapı olarak kullanmaktadır. Çalışma kapsamında teknoloji kabulü sonrası süreçte kullanıma devam etme niyetini etkileyen faktörleri belirlemek amacıyla kullanılan bu iki model, mobil alışveriş bağlamında test edilmiş ve kullanıcıların mobil alışveriş uygulamalarının ve sitelerinin kullanmaya devam etme niyetlerini açıklama güçleri yönünden birbirleriyle karşılaştırılmıştır. Veri analizi AMOS yazılımı kullanılarak yapısal eşitlik modellemesi (YEM) yöntemiyle yapılmıştır. Çalışma sonucunda BSBOM'un TKM'ye göre kullanıma devam etme niyetini çok daha yüksek oranda açıkladığı sonucuna ulaşılmış (BSBOM  $R^2 = \%71$ , TKM  $R^2 = \%53$ ) ve mobil alışveriş bağlamında teknoloji kabulü sonrası süreç içerisinde kullanım niyeti olgusunu incelemek için BSBOM'un TKM'ye göre daha etkili bir model olduğu ortaya konmuştur.*

**Anahtar Kelimeler:** Teknoloji Kabul Modeli, Bilgi Sistemleri Beklenti Onaylama Modeli, Model Karşılaştırma, Mobil Alışveriş, Kullanıma Devam Etme Niyeti

## ABSTRACT

*Today, with technological habits changing very fast, ensuring continuous use of a technology-based product or service is undoubtedly as important as least adoption. Hence, in recent years, the number of post-adoption studies has been increasing steadily. Many of these studies use the Technology Acceptance Model (TAM) or the Information Systems Expectation Confirmation Model (IS-ECM) as the theoretical background. In this study, these two models, which were used to determine the factors affecting the intention to continue using the technology after the adoption of the technology, were tested in the mobile shopping context and compared with each other in terms of their ability to explain their intention to continue using mobile shopping applications and sites. Data analysis was conducted by using structural equation modeling (SEM) method using AMOS software. Results indicate that IS-ECM has a larger explanatory power over TAM, explaining %71 of continuance intention in relation to %53 and it is revealed that IS-ECM is a more effective model than TAM in order to investigate the intention to use the technology in the mobile shopping context.*

**Keywords:** Technology Acceptance Model, Expectation Confirmation Model of IS, Model Comparison, Mobile Shopping, Continued Usage Intention.

## Information of Author(s):

\* Mehmet Cem Bölen  
mehmetcem.bolen@atauni.edu.tr  
Atatürk Üniversitesi, Açıköğretim Fakültesi

Üstün Özen  
uozen@atauni.edu.tr  
Atatürk Üniversitesi, İİBF, Yönetim Bilişim Sis. Böl.

Ersin Karaman  
ersinkaraman@atauni.edu.tr  
Atatürk Üniversitesi, İİBF, Sayısal Yöntemler Bölümü

\* Contact Author  
**Address:** Atatürk Üniversitesi, Açıköğretim Fakültesi, İşletme Lisans Programı, Erzurum  
**Telephone Number:** +90 442 231 5597

Submit Date: 21.11.2017  
Accept Date: 06.12.2017  
Publish Date: 29.12.2017





## 1. GİRİŞ

Günümüzde bilişim teknolojilerinin /sistemlerinin (BT/S) iş dünyası ve sosyal hayatın hemen hemen her alanında geniş çaplı bir etkiye sahip olduğu yadsınmaz bir gerçektir [1]. Artık finanstan tıpa birçok iş kolunda BT/S kullanımı bireyler ve kurumlar için temel bir ihtiyaç haline gelmiştir [2]. Bireyler BT/S'yi kişisel amaç ve isteklerini yerine getirmelerini kolaylaştırıcı bir araç olarak görürken [3], örgütler ise pazarda rekabet avantajı elde etmek ve stratejik hedeflerine ulaşmak için büyük yatırımlar yapılması gereken bir alan olarak görmektedirler [4]. Bununla birlikte gerek kişiler gerekse de kurumlar için BT/S'den elde edilebilecek faydalar, ne derece kullanıldıklarına bağlıdır [3]. Bir başka deyişle, sürekli kullanım davranışı ya da sürdürülebilir kullanım olgusu, teknoloji temelli bir ürününün veya hizmetinin sağlayacağı yarar veya katma değer noktasında kritik öneme sahiptir [5].

Özellikle 2000'li yıllardan itibaren bilgi teknolojilerinin ve sistemlerinin sürdürülebilir kullanımını etkileyen faktörlerin belirlenmesine yönelik farklı teorileri temel alan birçok çalışma yürütülmüştür. Bu çalışmalardan bazıları Teknoloji Kabul Modeli [6], Birleştirilmiş Teknoloji Kabul ve Kullanım Modeli [7] gibi bilişim sistemleri alanında sıkça kullanılan teorileri temel almaktayken bazıları ise Olumsuzluk Kuramı [8], İki Faktör Teorisi [9], İtme, Çekme ve Durdurma Kuramı [10], Sosyal Sermaye Teorisi [11] ve Beklenti Onaylama Teorisi [12] gibi farklı disiplinlerde geliştirilen teorileri kuramsal altyapı olarak kullanmışlardır. Ancak kullanıma devam etme niyetini ya da davranışını açıklamak için kullanılan bu teorilerin/kuramların birçoğu özel olarak BT/S'nin benimsenmesi veya kabulünü etkileyen faktörleri incelemek için geliştirilmiştir. Öte yandan kullanmayı kabul etme ve kullanmaya devam etme davranışları arasındaki temel farklılık göz önüne alındığında, teknoloji kabulü süreci için geliştirilen teoriler “sürekli kullanım” olgusunu açıklamada yetersiz kalabilmektedir [13]. Nitekim BT/S kullanıcılarının sürekli kullanım niyetini/davranışını incelemek için araştırmacıların hangi teorilerden yararlandığını belirlemek amacıyla yapılan güncel bir literatür tarama çalışmasının [14] sonuçlarına göre “sürdülebilir kullanım” olgusu ağırlıklı olarak teknoloji kabul modeli (TKM) [6] ve bilgi sistemleri beklenti onaylama modeli (BSBOM) [12] temel alınarak incelenmektedir.

BSBOM, bir BT/S'nin benimsenmesinden sonra sürekli ya da uzun süreli kullanımını etkileyen faktörleri belirlemek amacıyla geliştirilen ve sadece benimsenme sonrası süreci (post-adoption) inceleyen bir modeldir. TKM ise bir BT/S ile ilk kez karşılaşıldıktan sonra kullanılmaya başlandığı ve benimsendiği sürece kadar olan zaman aralığını (pre-adoption) incelemekte ve kullanım niyetini bu süreçte oluşan algılara göre açıklamaktadır [14], [15]. Bu yüzden kullanıma devam etme niyetini ölçerken TKM kullanıcı algılarını, BSBOM ise kullanıcı deneyimini temel almaktadır [16]. Dolayısıyla bu iki teorinin sürekli kullanım olgusunu farklı perspektiflerden yorumladığı ve açıklama güçlerinin birbirinden anlamlı derecede farklı olduğu öne sürülmektedir.

TKM ve BSBOM, bilişim sistemleri alanında çalışan araştırmacılar tarafından teknoloji benimsenmesi (kabulü) sonrası süreçte kullanıma devam etme niyetini ölçmek amacıyla yaygın olarak kullanılmaktadır.

Ancak bu çalışmalar incelendiğinde birçoğunda söz konusu iki teoriden birinin tercih edilme sebepleri genelde araştırmacının varsayımlarına, literatürde farklı bağlamlarda yapılan önceki çalışmaların sonuçlarına ya da teorinin ana düşüncesine dayandırıldığı görülmektedir. Kuşkusuz bunun bir nedeni de literatürde söz konusu iki teoriyi aynı bağlamda ampirik olarak karşılaştırarak inceleyen çalışma sayısının sınırlı sayıda olmasıdır. Bu doğrultuda, çalışma kapsamında TKM ve BSBOM sürekli kullanım niyetini açıklama güçleri temel alınarak karşılaştırmalı olarak incelemiştir. Çalışma sonucunda elde edilen bulguların mobil alışveriş bağlamında sürekli kullanım niyetini ölçmekte hangi modelin daha başarılı olduğu konusuna ışık tutması amaçlanmaktadır.

## 2. YÖNTEM

### 2.1. Araştırmanın Veri Toplama Yöntemi ve Ölçme Aracı

Çalışma kapsamında veri toplamak için anket yöntemi tercih edilmiştir. Anket tekniği çok sayıda sorudan oluşan bir soru formunun deneklere posta, telefon, internet ya da karşılıklı görüşme ile ulaştırılarak verdikleri cevapların kaydedilmesi aşamalarını kapsayan bir veri toplama tekniğidir [17]. Bu tekniğin uygulamasının ekonomik oluşu ve sistematik gözlemlerle elde edilemeyecek bilgilerin anketler kullanılarak elde edilmesi birçok bilimsel ya da

kamouyu araştırmasında tercih edilmesini sağlamıştır [18]. Bu çalışmada zaman, bütçe ve iş gücü kaynaklarının sınırlılıkları, katılımcılara yöneltilen soru sayısı, elde edilen verilerin örneklemeden daha büyük kitlelere genellenebilmesi gibi sebeplerden ötürü verilerin toplanması aşamasında kantitatif araştırmalarda en fazla başvurulan tekniklerinden biri olan “anket” tercih edilmiştir.

Çalışmada kullanılan anket formu herhangi bir maliyetinin olmaması (anketör, posta vb.) ve veri toplama sürecinde kayıp verilerin oluşmasının önüne geçilmesi için internet üzerinden hedef kitleye ulaştırılmıştır. Bu amaçla web tabanlı profesyonel bir anket oluşturma aracı olan www.surveey.com’dan yararlanılmıştır.

Çalışmada kullanılan anket formu iki bölümden oluşmaktadır. İlk bölümde katılımcıların demografik özelliklerini belirleyen değişkenler kullanılmıştır. Bu değişkenler katılımcıların yaşını, cinsiyetini, eğitim seviyesini ve daha önce mobil cihazlarda özel alışveriş kulübü uygulamaları ya da siteleri üzerindeki deneyimini belirlemeye yöneliktir

Anket formunun ikinci bölümünde yer alan sorular ise BSBOM ve TKM kapsamında yer alan faktörlerin ölçülmesine yöneliktir. Araştırmada kullanılan ölçekler orjinal BSBOM ve TKM’den alınarak mobil alışveriş bağlamına uyarlanmıştır. İki araştırma modelinde kullanılan ölçeklerin hepsi daha önce farklı çalışmalarda kullanılmış ve bu çalışmalarda ön testi yapılmış, geçerliliği ve güvenilirliği ispat edilmiştir. Ek 1’de anketin ikinci bölümünde kullanılan sorular, ait olduğu ölçekler ve alındığı kaynaklar görülmektedir.

Ankete katılım gönüllük esasına dayalı olup, ankete erişim adresi Ankara, Samsun ve İstanbul Avrupa Yakası’nda M.E.B’na bağlı devlet okullarında görev yapan, Atatürk Üniversitesi Açıköğretim Fakültesi sınavlarında görev almak amacıyla sisteme kaydolmuş öğretmenlere 29.11.2016 tarihinde elektronik posta ile gönderilmiştir

Anket 29.12.2016 tarihine kadar yayında kalmış ve bu tarihten sonra yayından kaldırılmıştır.

Araştırmanın verileri SPSS 20.0 ve AMOS 20.0 paket programları kullanılarak Yapısal Eşitlik Modeli (YEM) yöntemi ile analiz edilmiştir. YEM, tüm çözümlenelerde hataları açıkça hesaba katması ve hata sonuçlarında oldukça net sonuçlar ortaya koyması, birçok analizi bir defada yapması ve aracılık etkilerini kolaylaştırması gibi özelliklerinden ötürü günümüzde birçok teoremin test edilmesinde kullanılmaktadır [19]. Bu yüzden çalışmanın analiz yöntemi olarak YEM seçilmiştir.

Literatürde YEM’in uygulanması ile ilgili farklı görüşler bulunmakla birlikte bu araştırmada Anderson ve Gerbing [20] tarafından önerilen iki aşamalı yaklaşım benimsenmiştir. İki aşamalı yaklaşımın temel avantajı, ölçme modelinde uyum ve geçerliliğin test edilmesi sonucu yapısal modelde kullanılan değişkenlerin daha iyi ölçümlerle analizinin yapılmasına olanak tanınmasıdır. Bu yüzden analiz aşamasında Anderson ve Gerbing [20]’in önerisine uyularak öncelikle ölçme modeli test edilmiş, ardından yapısal model analizine geçilmiştir.

## 2.2 Araştırmanın Evreni ve Örnekleme Süreci

Bu araştırmanın ana kütlesi Türkiye’de faaliyet gösteren 4 büyük özel alışveriş kulübünün mobil site ya da uygulamasını mobil cihazlarında (Tablet bilgisayar, cep telefonu vb.) kullanan X ve Y yaş kuşağı gruplarına mensup kişilerdir. Zaman ve bütçe kısıtlarından ötürü araştırmada tesadüfi olmayan örneklem yöntemleri arasından, kolayda örnekleme yönteminin kullanılması tercih edilmiştir. Çalışmanın sonuçlarının tutarlı olması ve modelde yer almayan demografik değişkenlerin sonuçlara etkisini azaltmak açısından örneklem grubunun aynı meslek grubuna mensup, eğitim ve gelir düzeyleri birbirine benzer kişilerin olması hedeflenmiştir. Bunu sağlamak amacıyla Atatürk Üniversitesi Açıköğretim Fakültesi Görevli İşletim Sisteminin veritabanına kayıtlı, İstanbul, Ankara ve Samsun illerinde ikamet eden toplam 24488 öğretmenin e-posta adresine ankete ilişkin katılım linkinin yer aldığı bir mesaj gönderilmiştir. Gönderilen 24488 maile geri dönüş oranı %4.43 olarak gerçekleşmiş ve toplam 1085 kişiden geri dönüş alınmıştır. Veri giriş adımı tamamlandıktan sonra uygulanan filtre işlemi sonrası toplam 322 katılımcının mobil cihazlarında anket formunda yer verilen özel alışveriş kulüplerini kullandıkları tespit edilmiştir. YEM kullanılarak gerçekleştirilen veri analizlerinde örneklem hacminin olması gereken büyüklüğü çeşitli araştırmacılar tarafından en az 200 olmak kaydıyla 200-500 aralığında ifade edildiğinden [21], [22], söz konusu örneklem hacmi yeterli bulunmuştur.

### 3. BULGULAR

Tablo 1’de katılımcıların bazı demografik bilgileri yer almaktadır.

**Tablo 1.** Katılımcıların Demografik Bilgileri

Özellik		Sayı	Yüzde (%)	Özellik		Sayı	Yüzde (%)
Yaş	21-29	14	4,3	Eğitim	Lisans	268	83,2
	30-37	102	31,7		Yüksek Lisans	50	15,5
	38-44	99	30,7		Doktora	4	1,2
	45-50	107	33,2				
Cinsiyet	Erkek	100	31,1				
	Kadın	222	68,9				
Kullanılan Özel Alışveriş Kulübü	1v1y	95	29,5	Mobil Satın Alma İşlemi Yapılan Özel Alışveriş Kulübü	1v1y	62	19,3
	Markafoni	218	67,7		Markafoni	167	51,9
	Morhipo	219	68		Morhipo	154	47,8
	Trendyol	237	73,6		Trendyol	181	56,2
	Hiçbiri	0	0		Hiçbiri	65	20,2

Araştırma kapsamında seçilen 3 ilden (İstanbul, Ankara, Samsun) toplam 1085 kişiden (%49,49 erkek, %50,5 kadın), 322 tanesi mobil cihazlarında ankette yer bulan özel alışveriş kulüplerinden en az birinin uygulamasını ya da mobil sitesini kullandığını belirtmiştir. Tablo 1’de görüldüğü üzere söz konusu 322 kişinin %31,1’i erkek, %68,9’u kadındır. Katılımcıların %83,2’si lisans mezunu, %15,5’i yüksek lisans mezunu ve sadece %1,2’si doktora mezunudur. Yaş aralıklarına bakımından ise katılımcıların %4,3’ünün 21-29, %31,7’sinin 30-37, %30,7’sinin 38-44 ve %33,2’sinin 45-50 yaş aralığında oldukları görülmektedir. Son olarak özel alışveriş kulüplerinin mobil uygulamaları veya sitelerinin katılımcılar tarafından kullanımı ve bu uygulamalardan gerçekleştirdikleri satın alma oranlarının birbirine çok yakın olduğu, sadece 1v1y.com’un %29,5 kullanım oranı ve %19,3 satın alma oranı ile ortalamanın altında kaldığı görülmektedir. Ayrıca mobil cihazlarında söz konusu özel alışveriş sitelerinden en az birinin mobil uygulamasını ya da sitesi kullanan 65 kişi, bu uygulamalar veya sitelerden herhangi bir satın alma işlemi gerçekleştirilmemiştir. Katılımcıların önemli bir kısmının (%20,2) mobil uygulama ya da sitelerini satın alma işlemi gerçekleştirilmeden kullanmayı tercih etmeleri, mobil kanalları zaman geçirme, fiyat araştırması yapmak ya da ürün çeşitleriyle ilgili daha fazla bilgi sahibi olmak amacıyla kullanmalarından kaynaklanabilir.

Katılımcıların demografik özellikleri belirlendikten sonra veri setinin araştırma kapsamında incelenen modelleri destekleyip desteklemediğinin değerlendirilmesi aşamasına geçilmiştir. Çalışmanın yöntem kısmında belirtildiği üzere YEM analizinde Anderson ve Gerbing [20] tarafından önerilen iki aşamalı metodoloji benimsenmiştir. Bu yaklaşıma göre hem ölçme hem de yapısal modelin uyum ve geçerliliğine bakılmaktadır [23]. Dolayısıyla ilk olarak ölçme modelinin güvenilirliği, geçerliliği ve uyum iyiliği sağlanıp daha sonra yapısal model analizi gerçekleştirilmiştir. Bu doğrultuda ölçme modeline doğrulayıcı faktör analizi uygulanmıştır. Tablo 2’de doğrulayıcı faktör analizi sonucu ortaya çıkan TKM ve BSBOM’a ilişkin uyum indislerinin sonuçları görülmektedir.

YEM analizinde değerlendirilen bir modelin veri ile uyumlu olup olmadığı ya da teorik modelin elde edilen veriyi ne ölçüde iyi açıkladığı, ortaya çıkan çeşitli uyum indeks değerlerine göre belirlenir [24],[25]. Tablo 2’de görüldüğü üzere her iki modelin de uyum indisleri önerilen değerlerin üzerindedir.

**Tablo 2.** TKM ve BSBOM Ölçme Modelleri Uyum İndisleri

Uyum İndisi	Önerilen Değer	TKM	BSBOM
GFI	>0.90	.94	.92
AGFI	>85	.91	.88
CFI	>0.95	.98	.97
NFI	>0.90	.96	.96
NNFI	>0.90	.97	.96
S-RMR	<0.10	.037	.038
RMSEA	<0.08	.06	.07
Ki-kare	<5	2.202	2.918

Her iki modelin ölçme modellerinin istatistiksel olarak anlamlı ve uygun bir model olduğunu ortaya koyduktan sonra sıra söz konusu ölçme modellerinin güvenilirlik ve geçerliliklerinin değerlendirilmesi aşamasına geçilmiştir. Tablo 3'te TKM ve BSBOM'un ölçme modellerinin güvenilirlik ve geçerliliklerini ortaya koymak amacıyla modellerdeki her bir değişken için hesaplanan Cronbach Alpha, birleşik güvenilirlik (BG) ve ortalama açıklanan varyans (OAV) değerlerine yer verilmiştir.

**Tablo 3.** TKM ve BSBOM Ölçeklerinin Cronbach Alpha, BG, OAV Değerleri

Model	Yapı	Cronbach Alpha	Birleşik Güvenirlik	OAV
TKM	AKK	0,904	0,923	0,749
	AF	0,929	0,914	0,728
	NIY	0,920	0,922	0,747
BSBOM	ONY	0,885	0,886	0,796
	AF	0,929	0,893	0,676
	DOY	0,951	0,932	0,822
	NIY	0,920	0,921	0,747

TKM ve BSBOM'da kullanılan ölçeklerin güvenilirliği Cronbach Alfa katsayısı ve birleşik güvenilirlik değerleri ile test edilmiştir. Cronbach Alpha değerinin 0,70 ve üzerinde olması ölçeğin içsel tutarlılığını göstermesi açısından önemli bir kriter olarak görülmekle birlikte [26], yapısal eşitlik modellerinin kullanıldığı çalışmalarda birleşik güvenilirlik katsayısının da hesaplanması ve ölçeğin genel güvenilirliğine bu katsayının aldığı değere göre karar verilmesi önerilmektedir [27];[28]. Hair vd. [29], birleşik güvenilirlik katsayısı için 0.60 ile 0.70 arasındaki değerlerin kabul edilebilir, 0.70 ve üzerindeki değerlerin ise iyi düzeyde olduğunu belirtmişlerdir. Tablo 3'te görüldüğü üzere TKM ve BSBOM'da yer alan tüm ölçeklere ilişkin Cronbach Alpha ve birleşik güvenilirlik değerleri 0.70'in çok üstündedir. Dolayısıyla her iki modelin güvenilirlik açısından bir problemi yoktur.

Güvenilirlik testinin ardından ölçeklerin geçerlilik analizini gerçekleştirilmiştir. Geçerlilik, bir ölçeğin sahip olması gereken temel unsurlardan biridir. Yakınsak ve ayırt edici geçerliliğe sahip olan bir ölçek, yapısal olarak geçerli kabul edilir. Bu yüzden TKM ve BSBOM modellerinin ölçüm ve yapısal modelleri test edilmeden önce doğrulayıcı faktör analizi ile yakınsak (convergent validity) ve ayırt edici geçerlilikleri (discriminant validity) kontrol edilmiştir.

Yakınsak geçerlilik, bir faktör altında ölçme yapmak için belirlenen göstergelerin tümünün o faktörde oldukça yüksek yüklerle sahip olup olmadığını test etmektedir [30]. Yakınsak geçerliliğinin sağlanabilmesi için ölçeklerin ortalama açıklanan varyans değerleri 0.5'in ve birleşik güvenilirlik katsayısı da 0.70'in üzerinde olmalıdır [31],[32]. Ölçeklerin güvenilirlikleri yorumlanırken de belirtildiği üzere birleşik güvenilirlik katsayısı her iki model için de kabul edilebilir değer olan 0.70'in üstündedir. OAV oranı ise her iki modeldeki tüm yapılar için önerilen minimum değer 0.50'den yüksektir [33]. Dolayısıyla her iki modelde yer alan ölçeklerin tümü yakınsak geçerlilik için gereken şartları sağlamaktadır.

**Tablo 4.** TKM için Ayrışma Geçerliliği

	OAV	NIY	AF	AKK
NIY	0,747	<b>0,864</b>		
AF	0,728	0,721	<b>0,854</b>	
AKK	0,749	0,606	0,768	<b>0,866</b>

**Tablo 5.** BSBOM için Ayrışma Geçerliliği

	OAV	ONY	AF	DOY	NIY
ONY	0,796	<b>0,892</b>			
AF	0,676	0,689	<b>0,822</b>		
DOY	0,822	0,872	0,729	<b>0,906</b>	
NIY	0,747	0,770	0,754	0,800	<b>0,864</b>


Tablo 4 ve Tablo 5'te görüldüğü üzere TKM ve BSBOM'da yer alan tüm değişkenlerin ortalama açıklanan varyanslarının karekökü, modelde yer alan diğer değişkenlerin ilgili değişken ile olan korelasyon katsayısından daha büyüktür. Dolayısıyla TKM ve BSBOM'da yer alan tüm ölçekler için ayrışma geçerliliğinin sağlandığı görülmektedir.

Güvenilir ve geçerli bir ölçme modeline ulaşıldığına emin olduktan sonra TKM ve BSBOM'un yapısal modellerinin testine geçilmiştir. Tablo 6'da görüldüğü üzere her iki yapısal modele ilişkin uyum indisleri önerilen değerlerin üzerindedir.

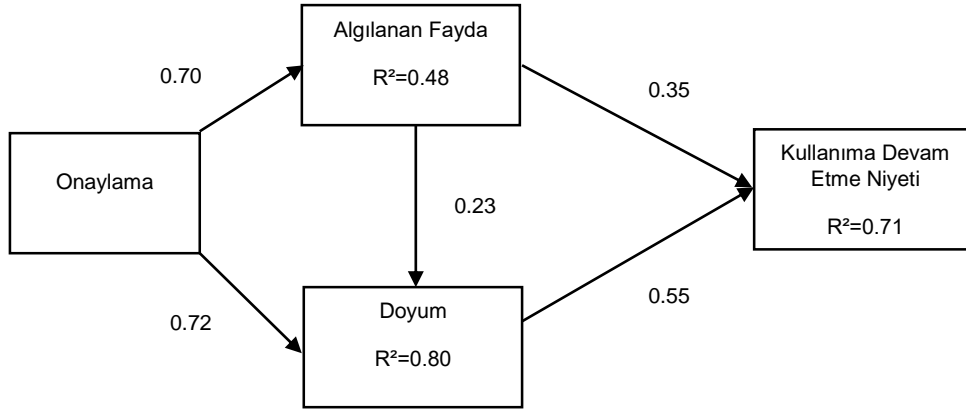
**Tablo 6.** TKM ve BSBOM Ölçme Modelleri Uyum İndisleri

Uyum Indisi	Önerilen Değer	TKM	BSBOM
GFI	>0.90	.92	.92
AGFI	>85	.88	.88
CFI	>0.95	.96	.97
NFI	>0.90	.95	.95
NNFI	>0.90	.95	.96
S-RMR	<0.10	.039	.035
RMSEA	<0.08	.08	.07
Ki-kare	<5	3.136	2.961

Şekil 1 ve Şekil 2'de söz konusu modellerin standardize edilmiş yol katsayıları ve kullanıma devam etme niyetini açıklama oranlarının ( $R^2$ ) yer aldığı yapısal modeller görülmektedir.



Şekil 1. TKM Yapısal Model Analiz Sonuçları



Şekil 2. BSBOM Yapısal Model Analiz Sonuçları

Şekil 1 ve Şekil 2 incelendiğinde TKM'de kullanıma devam etme niyetindeki %53 değişimin algılanan fayda ve algılanan kullanım kolaylığı tarafından açıklandığı, BSBOM'deki kullanıma devam etme niyetindeki %71'lik değişimin ise onaylama, algılanan fayda ve doyum değişkenleri tarafından açıklandığı görülmektedir.

Modeller incelenirken bakılması gereken bir başka değer ise standardize edilmiş yol katsayılarıdır. Kline [21]'e göre standardize edilmiş yol katsayılarının etki büyüklükleri şu şekilde sınıflandırılmaktadır; 0.50 ve üzerindeki değerler büyük, 0.30 civarındakiler orta, 0.10 ve atındaki değerler ise küçük etkiyi ifade etmektedir. Buna göre TKM'de algılanan kullanım kolaylığı ile algılanan fayda arasında pozitif yönde yüksek şiddette bir ilişki olduğu (0.78), algılanan kullanım kolaylığı ve kullanıma devam etme niyeti arasında pozitif yönde zayıf şiddette bir ilişki olduğu (0.10), algılanan fayda ve kullanıma devam etme niyeti arasında pozitif yönde yüksek şiddette bir ilişki olduğu (0.65) görülmektedir. BSBOM'da ise onaylama ile algılanan fayda ve doyum değişkenleri arasında pozitif yönde yüksek şiddette bir ilişki olduğu (0.70 ve 0.72), algılanan fayda ve doyum arasında pozitif yönde orta şiddette bir ilişki olduğu (0.23), benzer şekilde algılanan fayda ve kullanıma devam etme niyeti arasında pozitif yönde orta şiddette bir ilişki olduğu görülmektedir. Son olarak daha önce yapılan çalışmalarda da [2], [14] belirtildiği üzere kullanıma devam etme niyetinin en güçlü öncülünün doyum değişkeni olduğu (0.55) görülmüştür.

Model seçim kriteri olarak tek başına  $R^2$ 'nin kabul edilmesi her zaman yeterli olmayabilir [34]. Bu yüzden hangi modelin ele alınan veri setini daha iyi açıkladığına karar vermek adına  $R^2$  dışında başka kriterlerde kabul edilmektedir. Örneğin bilişim sistemleri literatüründe ağırlıklı olarak temel alınan kriter  $R^2$ 'ye (determinasyon katsayısı) bakılarak modelleri açıklama güçlerinin karşılaştırılması iken bilişsel psikolojide AIC (Akaike's Information Criteria), CAIC (Consistent AIC), BIC (Bayesian Info Criterion) değerleri de göz önünde

bulundurulmaktadır [35]. Tablo 7’de her iki modele ait AIC, CAIC, BIC değerleri ve kullanıma devam etme niyetine ilişkin  $R^2$  yer almaktadır.

**Tablo 6.** TKM ve BSBOM’ın Kullanıma Devam Etme Niyetini Açıklama Güçleri ve AIC, CAIC, BIC Değerleri

Model Adı	$R^2$	AIC	CAIC	BIC
TKM	%53	212.806	346.493	318.493
BSBOM	%71	238.677	391.462	359.462

İki veya daha fazla model karşılaştırılırken en uygun modeli bulmak için kullanılan AIC, CAIC ve BIC için kabul edilebilir ya da mükemmel uyum ölçütü olarak alınan sabit bir aralık yoktur [36]. Genelde AIC, CAIC ve BIC’de en düşük değere sahip model, en uygun model olarak kabul edilir. Ancak bu çalışmanın TKM ve BSBOM modellerinin kullanıma devam etme niyetini açıklama güçlerini sınaması ve iki modelin kullanıma devam etme niyetini açıklama güçleri arasındaki çok büyük farktan dolayı AIC, CAIC ve BIC değerleri arasındaki farkın ihmal edilebilecek büyüklükte olduğuna karar verilmiştir. Dolayısıyla  $R^2$  değeri temel alınarak BSBOM’un teknoloji benimsenmesi sonrası süreçte kullanıma devam etme niyetini açıklamak için TKM’ye göre daha uygun bir model olduğu sonucuna varılmıştır.

#### 4. TARTIŞMA ve SONUÇ

Kabul edilen bir teknolojinin kullanımında her zaman kesin bir sürdürülebilirliğin sağlanamayabileceği görüşünden hareketle son yıllarda sürdürülebilir kullanım olgusu farklı yaklaşımlar ile incelenmeye başlanmıştır. Bu yaklaşımlardan en önemlileri arasında yer alan BSBOM, teknoloji kabulü sonrası kullanım devamlılığını sağlamak için etkili olan faktörleri ortaya çıkarmak amacıyla çeşitli bağlamlarda (e-öğrenme, e-ticaret, mobil oyun vb.) genişletilerek ya da farklı teoriler ile sentezlenerek kullanılmaktadır. Bu çalışmada BSBOM, bilişim sistemleri alanının en etkili teorilerinden biri olan TKM ile özel alışveriş sitelerinin mobil alışveriş ve mobil sitelerinin kullanıcılarının kullanım niyetlerini açıklama güçleri bakımından karşılaştırılmıştır. Çalışma sonucunda elde edilen bulgular ışığında BSBOM’un TKM’ye göre kullanıma devam etme niyetini daha yüksek oranda açıkladığı görülmektedir. Ortaya çıkan bu bulgular, TKM ve BSBOM’u muhasebe ve bütçeleme yazılımları bağlamında karşılaştıran Halilovic ve Cicic [2] çalışmasındaki bulgulara benzerlik göstermektedir. Bununla birlikte Halilovic ve Cicic [2]’in çalışmasında BSBOM’un sürekli kullanım niyeti %49 oranında açıkladığı belirtilirken, mevcut çalışmada bu oranın %71’e çıktığı görülmüştür. Bu durum iki çalışmanın farklı bağlamlarda (mobil alışveriş ve masaüstü yazılımı) gerçekleştirilmesinden kaynaklanabilir. Ayrıca bu çalışmada ortaya çıkan sonuçlar, teknoloji kabulü sonrası süreçte kullanıma devam etme niyetini açıklama gücü yönünden TKM’yi BSBOM’dan daha üstün gösteren Hong vd. [35] ve Recker [15]’in çalışmalarının sonuçlarından önemli farklılık göstermektedir. Söz konusu çalışmalarda BSBOM, TKM ve her iki model sentezlenerek oluşturulan hibrit bir modelin kullanıma devam etme gücünü açıklama güçleri karşılaştırılmıştır. Her iki çalışmada da hibrit modelin kullanıma devam etme niyetini diğer modellerden daha yüksek oranda açıkladığı belirtilmiştir. Bu bakımdan mevcut çalışma literatürde konuyla ilgili yapılan çalışmalardan farklı bir bağlamda gerçekleştirilmesi ve söz konusu çalışmalardaki sonuçların tam tersini işaret eden bulgulara ulaşmasından ötürü anlamlı ve değerlidir.

Son olarak bu çalışma, gerek bütçe ve zaman gerekse yönteminden ötürü bazı sınırlılıklara sahiptir. En önemli sınırlılık çalışmanın örnekleme ile ilgilidir. Çalışmanın örneklemini sadece İstanbul, Ankara ve Samsun’da görev yapan öğretmenler oluşturmaktadır. Bu yüzden araştırmanın sonuçlarının farklı bölgelerde ikamet eden, birbirinden farklı gelir düzeylerine sahip tüm tüketicilere genellenebilirliği sınırlıdır. Modelde yer alan kullanıma devam etme niyeti, kullanım davranışının güçlü bir öncülü olsa da gelecek çalışmalarda niyet yerine davranış yapısının ölçülmesi daha doğru sonuçlara ulaşılmasını sağlayabilir.



## KAYNAKLAR

- [1] Roca, J. C., & Gagne, M. (2008). Understanding e-learning continuance intention in the workplace: A self-determination theory perspective. *Computers in Human Behavior*, 24(4), 1585-1604.
- [2] Halilovic, S., & Cicic, M. (2013). Understanding determinants of information systems users' behaviour: a comparison of two models in the context of integrated accounting and budgeting software. *Behaviour & Information Technology*, 32(12), 1280-1291.
- [3] Shaikh, A. A., & Karjaluoto, H. (2015). Making the most of information technology & systems usage: A literature review, framework and future research agenda. *Computers in Human Behavior*, 49, 541-566.
- [4] Cassidy, A. (2016). *A practical guide to information systems strategic planning (İkinci Baskı)*. Boca Raton: CRC press.
- [5] Deng, L. Q., Turner, D. E., Gehling, R., & Prince, B. (2010). User experience, satisfaction, and continual usage intention of IT. *European Journal of Information Systems*, 19(1), 60-75.
- [6] Davis, F. D. (1989). Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology. *Mis Quarterly*, 13(3), 319-340.
- [7] Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003). User acceptance of information technology: Toward a unified view. *MIS Quarterly*, 27(3), 425-478.
- [8] Khalifa, M., & Liu, V. (2007). Online consumer retention: contingent effects of online shopping habit and online shopping experience. *European Journal of Information Systems*, 16(6), 780-792.
- [9] Lee, S., Shin, B., & Lee, H. G. (2009). Understanding post-adoption usage of mobile data services: the role of supplier-side variables. *Journal of the Association for Information Systems*, 10(12), 2.
- [10] Hsieh, J.-K., Hsieh, Y.-C., Chiu, H.-C., & Feng, Y.-C. (2012). Post-adoption switching behavior for online service substitutes: A perspective of the push-pull-mooring framework. *Computers in Human Behavior*, 28(5), 1912-1920.
- [11] He, W., Qiao, Q., & Wei, K.-K. (2009). Social relationship and its role in knowledge management systems usage. *Information & Management*, 46(3), 175-180.
- [12] Bhattacharjee, A. (2001). Understanding information systems continuance: An expectation-confirmation model. *MIS Quarterly*, 25(3), 351-370.
- [13] Bhattacharjee, A., & Barfar, A. (2011). Information technology continuance research: current state and future directions. *Asia Pacific Journal of Information Systems*, 21(2), 1-18
- [14] Larsen, T. J., Sorebo, A. M., & Sorebo, O. (2009). The role of task-technology fit as users' motivation to continue information system use. *Computers in Human Behavior*, 25(3), 778-784.
- [15] Recker, J. (2010). Continued use of process modeling grammars: the impact of individual difference factors. *European Journal of Information Systems*, 19(1), 76-92.
- [16] Premkumar, G., & Bhattacharjee, A. (2008). Explaining information technology usage: A test of competing models. *Omega*, 36(1), 64-75.
- [17] Yıldırım, E. (2015). *İstatistiksel Araştırma Yöntemleri Su Tüketim Bilinci Üzerine Bir Kamuoyu Araştırması*. Ankara: Seçkin Yayınevi.
- [18] Baş, T. (2013). *Anket nasıl hazırlanır, nasıl uygulanır, nasıl değerlendirilir (Yedinci Baskı)*. Ankara: Seçkin Yayınevi.
- [19] Meydan, C. H., & Şeşen, H. (2015). *Yapısal eşitlik modellemesi AMOS uygulamaları (İkinci Baskı)*. Ankara: Detay Yayıncılık.
- [20] Anderson, J. C., & Gerbing, D. W. (1988). Structural Equation Modeling in Practice - a Review and Recommended 2-Step Approach. *Psychological Bulletin*, 103(3), 411-423.
- [21] Kline, R. B. (2005). *Principles and Practice of Structural Equation Modeling*. New York: Guilford Press.
- [22] Loehlin, J. C. (2004). *Latent Variable Models: An Introduction to Factor, Path, and Structural Equation Analysis*: Taylor & Francis.
- [23] Hair, J. F., Black, W. C., Babin, B. J., Anderson, R. E., & Tatham, R. L. (1998). *Multivariate Data Analysis (Beşinci Baskı)*. Upper Saddle River, New Jersey: Pearson Prentice Hall.
- [24] Hoyle, R. H. (1995). *Structural Equation Modeling: Concepts, Issues, and Applications*. California: SAGE Publications.
- [25] Byrne, B. M. (2010). *Structural Equation Modeling with AMOS: Basic Concepts, Applications, and Programming (İkinci Baskı)*. New York and London: Routledge.
- [26] Nunnally, J. C. (1978). *Psychometric theory*. New York: McGraw-Hill.
- [27] Raykov, T. (1997). Estimation of composite reliability for congeneric measures. *Applied Psychological Measurement*, 21(2), 173-184.
- [28] Ketchen, D. J., & Bergh, D. D. (2005). *Research Methodology in Strategy and Management*: Emerald Group Publishing Limited.



- [29] Hair, J., Black, W., Babin, B., & Anderson, R. (2010). *Multivariate Data Analysis (Yedinci Baskı)*. New Jersey: Pearson Prentice Hall.
- [30] Çokluk, Ö., Şekercioğlu, G., & Büyüköztürk, Ş. (2010). *Sosyal bilimler için çok değişkenli istatistik: SPSS ve LISREL uygulamaları*. Ankara: Pegem Akademi.
- [31] Bagozzi, R. P., & Yi, Y. (1988). On the evaluation of structural equation models. *Journal of the academy of marketing science*, 16(1), 74-94.
- [32] Gefen, D., Straub, D., & Boudreau, M.-C. (2000). Structural equation modeling and regression: Guidelines for research practice. *Communications of the association for information systems*, 4(1), 7.
- [33] Fornell, C., & Larcker, D. F. (1981). Evaluating Structural Equation Models with Unobservable Variables and Measurement Error. *Journal of Marketing Research*, 18(1), 39-50.
- [34] Gujarati, D. (2009), *Basic Econometrics*. Singapore: McGraw Hill.
- [35] Hong, S. J., Thong, J. Y. L., & Tam, K. Y. (2006). Understanding continued information technology usage behavior: A comparison of three models in the context of mobile internet. *Decision Support Systems*, 42(3), 1819-1834.
- [36] İlhan, M., & Çetin, B. (2014). LISREL ve AMOS programları kullanılarak gerçekleştirilen yapısal eşitlik modeli (yem) analizlerine ilişkin sonuçların karşılaştırılması. *Eğitimde ve Psikolojide Ölçme ve Değerlendirme Dergisi*, 5(2).

# Karar Ağaçları ile Bir Web Sitesinde Link Analizi ve Tespiti

Muhammed Çağrı Aksu, Ersin Karaman

## ÖZET

*Web siteleri metinler, resimler, videolar gibi içerikler ile ziyaretçilerine bilgi vermeyi amaçlayan uygulamalardır. Web sitesi ana sayfasının sitenin bir özeti olması ve çok tıklanan, çok zaman geçirilen ya da hemen çıkma oranı düşük olan alt sayfaların linklerini barındırması beklenmektedir. Büyük web siteleri yüzlerce ya da binlerce alt sayfa içermektedir. Bu alt sayfaların hepsinin linklerinin ana sayfaya konulması, ana sayfanın karmaşık bir hal almasına neden olur. Bu çalışmada, bir web sitesinin Google Analitik verilerini kullanarak, veri madenciliği yöntemiyle ana sayfada olması gereken linklerin tespitini yapabilmek için bir karar ağacı oluşturulmuştur. Oluşturulan karar ağacı mevcut ya da yeni yapılacak bir web sitesinin ana sayfasında olması gereken alt sayfalarının linklerinin tespitinde kullanılabilir. Böylelikle ana sayfanın daha işlevsel olması, ziyaretçilerin girmek istedikleri alt sayfaları daha hızlı bulmaları sağlanabilir.*

**Anahtar Kelimeler:** Veri Madenciliği, Google Analitik, WEKA, Sınıflandırma, C4.5

## ABSTRACT

*Web sites are webbased applications that intend to inform their visitors through contents such as texts, visuals and videos. The home page of a web site must be a summary of the web site. Home page must host the links for frequently or longterm visited subpages with lower possibility to exit immediately. Big web sites have hundreds or thousands of subpages. If the links of all these subpages are given in the home page, the page can become messed. In this research, a decision tree was formed through data mining method using Google Analytic data in order to identify the links necessary to be given in the home page of a web site. The decision tree can be used for the identification of the links of the subpages necessary to be given in the home page of a current or future web site. This can support the functionality of the home page and help the visitors easily find the subpages they would like to enter into.*

**Keywords:** Data Mining, Google Analytic, WEKA, Classification, C4.5

### Information of Author(s):

**Muhammed Çağrı Aksu\***  
m.cagri.aksu@gmail.com  
Artvin Çoruh Üniversitesi  
Enformatik Bölümü

**Ersin Karaman**  
karamanersin@gmail.com  
Atatürk Üniversitesi  
İktisadi ve İdari Bilimler Fakültesi  
İşletme Bölümü

Submit Date: 20.11.2017  
Accept Date: 21.12.2017  
Publish Date: 29.12.2017



### \* Contact Author

**Address:** Artvin Çoruh Üniversitesi Rektörlüğü 08100 Seyitler, Merkez, Artvin, Türkiye  
**Telephone Number:** 0534 644 64 64

## 1.GİRİŞ

Web siteleri metinler, resimler, videolar gibi içerikler ile ziyaretçilerine bilgi vermeyi amaçlayan uygulamalardır. İnternette kişisel web sitesi, kurumsal web sitesi, eticaret web siteleri gibi çeşitli web siteleri vardır. Kurumsal web siteleri bir kurum ya da kuruluş hakkında bilgi veren metinleri, kurum ya da kuruluşun haberlerini, duyurularını, etkinliklerini barındıran, genellikle o kurum ya da kuruluş ile alakalı kişilerin ziyaret ettiği web siteleridir.

Kurumsal web siteleri genellikle bir ana sayfa ve bu ana sayfaya bağlı birçok alt sayfalardan oluşmaktadır. Kurumsal bir web sitesinin ana sayfası, sitenin bir özeti şeklinde olmalıdır. Çok tıklanan, çok zaman geçirilen ya da hemen çıkma oranı düşük olan alt sayfaların linklerinin ana sayfada olması, web sitesinin işlevselliği açısından önem arz etmektedir. Büyük web sitelerinde yüzlerce, belki binlerce alt sayfa bulunmaktadır. Bu alt sayfaların her birine ana sayfada link vermek, ana sayfanın karmaşık bir hal almasına neden olmaktadır, bu da kullanıcıların aradıkları alt sayfayı bulmalarını zorlaştırmaktadır. Bu nedenle ana sayfada kullanıcıların çok ziyaret ettiği, çokça zaman geçirdiği, sayfadan hemen çıkmadığı alt sayfaların linklerinin bulunması gerekmektedir. Bu çalışmada Artvin Çoruh Üniversitesi web sitesinin Google Analitik verileri çeşitli karar ağacı algoritmalarıyla sınıflandırılmıştır. Sınıflandırma neticesinde en iyi sonucu veren algoritma ile bir karar ağacı oluşturulmuştur. Oluşturulan karar ağacı mevcut web sitesinin ana sayfasında bulunması gereken linklerin tespitinde kullanılmıştır.

Literatüre bakıldığında web sitelerinin fonksiyonelliğini artırmak için Google Analitik verilerinden ziyade web erişim günlükleri kullanılmıştır. Resul, Türkoğlu ve Poyraz bir web sitesinin erişim kayıtlarının analizini, web kullanım madenciliği ile gerçekleştirmişlerdir [1]. Daş, Türkoğlu çalışmalarında web kayıt dosyalarından ilginç örüntüleri keşfetmek konusu hakkındaki çalışmaları incelemişlerdir [2]. Tuğ, Şakiroğlu yaptıkları çalışmalarında genetik algoritma yöntemiyle web erişim kayıtlarından sıralı ilişkileri tespit etmişlerdir [3]. Carmona, RamírezGallego bir eticaret web sitesinin Google Analitik verileriyle çeşitli veri madenciliği işlemleri yapmışlardır [4]. Neticesinde web sitesinin kullanıcı memnuniyetini artıracak sonuçlar elde etmişlerdir. Parvatikar and Joshi web kayıt dosyalarını kullanarak çeşitli veri madenciliği teknikleriyle son kullanıcı ile ilgili bilgiler ortaya çıkarmışlardır [5].

## 2.YÖNTEM

Bu çalışmada Artvin Çoruh Üniversitesi web sitesinin 01.01.2015 - 01.01.2017 tarihleri arasındaki Google Analitik verileri kullanılmıştır. Bu veriler çeşitli sınıflandırma algoritmalarıyla sınıflandırılmış ve neticesinde en iyi sınıflandırma başarısına sahip olan algoritma ile bir karar ağacı oluşturulmuştur. Oluşturulan karar ağacı ile üniversitenin ana sayfasında olması gereken linklerin tespit edilmesi amaçlanmıştır. Çalışmada kullandığımız veriler içerisinde web sitesinde bulunan sayfaların, sayfa görüntüleme sayısı, tekil sayfa görüntüleme sayısı, sayfada kalma süresi, giriş sayıları, çıkış oranı, hemen çıkma oranı alanları bulunmaktadır. Tablo 1’de verilerin bir örneği gösterilmektedir. 21371 adet veri içerisinde duyuru linkleri, etkinlik linkleri, haber linkleri gibi yapılacak işlemlerle alakalı olmayan veriler temizlenmiş geriye 2536 adet veri kalmıştır.

**Tablo 1.** Google Analitik Veri Örneği

Sayfa Linki	Sayfa Gör. Sayısı	Tekil Sayfa Gör. Sayısı	Ort. Kal. Süre.	Giriş Sayısı	Çıkış Oranı	Hem. Çık. Oranı
/tr/menu/137/131/egitim-fakultesi	140585	84038	44	20720	13	22
/tr/menu/145/134/artvin-myoy	107951	70164	62	26663	24	36

/tr/menu/131/19/fakulteler	106666	73313	14	1699	5	26
/tr/menu/147/134/hopa-myo	80020	52797	57	30766	26	32
/tr/menu/19/16/akademik	79796	51726	11	987	4	32
/tr/menu/1018/968/idari	1431	912	113	10	13	30

Veriler temizlendikten sonra geliştirilen küçük bir web tabanlı program ile bu 2536 adet verinin hangilerinin linklerinin, mevcut ana sayfada buldukları tespit edilmiştir. Bu web tabanlı uygulama mevcut web sitesinin ana sayfasının kaynak koduna bakmakta, Tablo 1’de örneği gösterilen verilerin sayfa linki alanını kaynak kod ile karşılaştırmakta, kaynak kod içerisinde sayfanın linkini tespit ederse bu verinin ana sayfada bulunup bulunmama alanını “true” olarak belirlemekte, eğer kaynak kod içerisinde sayfanın linkini tespit edemezse “false” olarak belirlemektedir. Böylece tüm verilere bir alan daha eklenmiştir. Bu alan sayfanın ana sayfada linkinin bulunup bulunmadığını gösteren bir alandır. Eğer sayfanın ana sayfada linki bulunuyorsa “true”, bulunmuyorsa “false” değerini içermektedir.

**Tablo 2. Veri Madenciliğine Hazır Hale Getirilmiş Verilerin Örneği**

Sayfa Gör. Sayısı	Tekil Sayfa Gör. Sayısı	Ort. Kal. Süre.	Giriş Sayısı	Çıkış Oranı (%)	Hem. Çık. Oranı (%)	Ana Sayf. Linki Var Mı?
140585	84038	44	20720	13	22	True
107951	70164	62	26663	24	36	True
106666	73313	14	1699	5	26	True
80020	52797	57	30766	26	32	True
79796	51726	11	987	4	32	True
1431	912	113	10	13	30	False

Veriler, yukarıda belirtildiği gibi düzenlendikten sonra Tablo 2’de görüldüğü gibi veri madenciliği yapılacak hale getirilmiştir. Daha sonra veriler, veri madenciliği uygulamalarında sıklıkla kullanılan Weka programı vasıtasıyla, karar ağacı algoritmalarından C4.5, Random Forest, REP Tree, Logistic Model Tree ve CART algoritmaları kullanılarak sınıflandırılmıştır. Sınıflandırma başarısı en yüksek olan C4.5 algoritması ile karar ağacı oluşturulmuştur. Oluşturulan bu karar ağacıyla ana sayfada bulunması gereken linklerin tespit edilmesi amaçlanmıştır. Bu karar ağacı mevcut web sitesi için kullanılacağı gibi yeniden yapılması planlanan site için de kullanılabilir. Böylelikle web sayfasının daha fonksiyonel ve kullanışlı olması sağlanabilir.

Bu kısımdan sonra, yöntemin alt başlıklarında, çalışmanın yöntemi olan veri madenciliği, karar ağaçları, Google Analitik, çalışmada kullanılan karar ağacı algoritmaları ve Weka programı hakkında bilgiler verilmektedir.

## 2.1. Veri Madenciliği

Bilişim teknolojilerindeki gelişmeler neticesinde, artık her veri sayısal ortama kaydedilmektedir ve veri tabanlarında milyonlarca veri biriktirmektedir. Biriken bu veriler saklandığı yerde öylece beklerken bir anlam ifade etmemektedirler. Bu verilerin anlam ifade eden yararlı bilgilere dönüştürülmesi gerekmektedir. Verilerin anlam ifade eden bilgilere dönüştürülmesi veri madenciliği vasıtasıyla olmaktadır [6]. Aşağıda veri madenciliğinin ne olduğunu gösteren farklı tanımlar verilmiştir.

- Veri madenciliği daha önceden bilinmeyen, geçerli ve uygulanabilir bilgilerin geniş veri tabanlarından elde edilmesi ve bu bilgilerin işletme kararları alınırken kullanılmasıdır [7].
- Veri madenciliği büyük miktarda veri içinden gelecekle ilgili tahmin yapmamızı sağlayacak bağıntı ve kuralların bilgisayar programları kullanarak aranmasıdır [8].

Veri madenciliğinde birçok yöntem ve algoritma bulunmaktadır, ancak genel olarak veri madenciliği sınıflandırma, kümeleme ve birliktelik kuralları olarak üç ana başlığa ayrılmaktadır. Sınıflandırma, sınıfı tanımlanmamış verileri kullanarak sınıfı belli olmayan verilerin sınıfını tahmin etmek için kullanılan bir yöntemdir. Sınıflandırmanın ilk aşamasında veriler herhangi bir sınıflandırma algoritmasına tabi tutulmakta ve kurallar oluşturulmaktadır. Sınıflandırmanın ikinci aşamasında ise ilk aşamada oluşturulan kurallar, sınıfı belli olmayan veriler üzerine uygulanmakta ve verilerin sınıfı tahmin edilmektedir [9]. Kümelemede, verilerin benzerliklerine göre kümelenmesi işlemleri bulunmaktadır [6]. Birliktelik kurallarında ise veriler içerisinde bulunan birliktelik ilişkilerinin çıkarılması işlemi yapılmaktadır. Veriler içerisindeki tüm kombinasyonlara bakılmakta, birbiri ile ilişkili olan veriler keşfedilmeye çalışılmaktadır [10].

## 2.2.Karar Ağaçları

Karar ağaçları, veri madenciliğinde sınıflandırma tekniklerinden birisidir. Sınıflandırma problemlerinde çokça kullanılmaktadır. Karar ağaçlarında önce bir karar ağacı oluşturulmakta, daha sonra karar ağacından üretilen kurallar ile veri tabanında bulunan kayıtlar sınıflandırılmaktadır [7].

Karar ağaçlarında ID3, C4.5, Sliq, Sprint, CART, REP Tree, Random Forest, Logistic Model Tree gibi birçok algoritma kullanılabilir. Veriler önce bu karar ağacı algoritmalarından birine gönderilir. Algoritma bu verileri işler ve bir karar ağacı oluşturur. Oluşturulan bu karar ağacı sınıfı bilinmeyen veriler üzerine uygulanarak bu verilerin sınıflarının tespit edilmesi sağlanır.

## 2.3.C4.5 Algoritması

C4.5 algoritması 1993 yılında Quinlan tarafından ortaya çıkarılmış bir karar ağacı algoritmasıdır. Bu algoritma ile sayısal veriler karar ağaçlarında kullanılabilir hale gelmiştir. C4.5 algoritması yine Quinlan tarafından geliştirilen ID3 algoritmasının daha gelişmiş halidir. ID3 algoritmasında kayıp veriler hesaba katılmazken C4.5 algoritmasında kayıp verilerin değerleri tahmin edilerek kullanılmaktadır [6].

C4.5 algoritması sınıflandırma işlemini verilerin sıklıklarına göre yapmaktadır. Veri kümesindeki düzensizliği gösteren entropi hesabına bağlı olarak çalışmaktadır. C4.5 algoritmasının çalışma şekli aşağıdaki gibi açıklanabilir.

- $\sum_{i=1}^n p_i \log_2 p_i$  formülüne göre veri kümesindeki tüm sütunların entropisi hesaplanır [11].
- Veri kümesindeki her bir sütunun entropisi, sınıfın entropisine bölünerek her bir sütunun kazancı hesaplanır.
- Kazancı en yüksek olan kök düğüm olarak atanır.

Kök düğümün ait olduğu veriler haricinde kalan veriler için aynı işlemler tekrarlanır. Tüm veriler bitene kadar aynı işlemler devam eder [12].

## 2.4.REP Tree Algoritması

Bu algoritma ilk olarak Quinlan tarafından önerilmiştir [13]. REP Tree algoritmasında, regresyon ağacı mantığıyla, farklı yinelemelerde birden fazla ağaç oluşturulmakta ve daha sonra oluşturulan bu karar ağaçlarından en iyisini seçilmektedir. Algoritma varyansdan kaynaklanan hatayı en aza indirme ilkesine ve entropi ile bilgi kazanımı ilkesine dayanmaktadır [14-16].

## 2.5.Random Forest Algoritması

Bu algoritma Breiman tarafından ileri sürülmüştür. Özellikle büyük miktarda verilerin sınıflandırılmasında iyi performans göstermektedir. Amacı tek bir karar ağacı üretmek yerine her biri farklı eğitim kümelerinde eğitilmiş

olan çok sayıda karar ağacını birleştirmektedir. Farklı eğitim kümeleri oluştururken ön yükleme ve rastgele özellik seçimi kullanılmaktadır [17, 18].

## 2.6.CART Algoritması

1984 yılında Breiman tarafından oluşturulmuş bir algoritmadır. CART algoritmasında karar ağaçları, her bir karar düğümünün çeşitli ayrılma kriterleri ile iki farklı dala ayrılmasıyla oluşturulmaktadır [6, 19].

## 2.7.Logistic Model Tree Algoritması

Logistik Model Tree, kısaca LMT, indiksiyon ağaçlarının ve lojistik regresyonun birleştirilmesiyle oluşmuş bir algoritmadır. Bu algoritmada, ağacın her düğümünde bir lojistik regresyon modeli üretmek için LogitBoost algoritması kullanılmakta, daha sonra düğümler C4.5 kriterleri kullanılarak bölünmektedir [20, 21].

## 2.8.Google Analitik

Google Analitik, dünyanın en büyük arama motoru olan Google'ın web sitesi sahipleri için sunduğu web sitesi analiz aracıdır. Google analitik ile web sitesi ziyaretçilerinin, web sitesine nasıl ulaştıkları ve sitede ne gibi işlemler yaptıkları kolayca analiz edilebilmektedir. Google analitik ile elde edilen bilgiler ile site tasarımı geliştirilebilmekte, girilen içeriklerin ilgi çekip çekmediği anlaşılabilen ve web sitesi daha işlevsel hale getirilebilmektedir [22].

Google analitik ile belirttiğiniz tarihler arasında web sitenize gelen ziyaretçilerin sayısı görülebileceği gibi anlık ziyaretçi sayıları da görülebilmektedir. Ayrıca Google Analitik ile web sitenizde her bir sayfanın detaylı istatistiksel bilgisi alınabilmektedir. Google Analitiğin sunduğu istatistiksel veriler içerisinde sayfa görüntüleme sayısı, tekil sayfa görüntüleme sayısı, sayfada geçirilen süre, giriş sayısı, çıkış oranı, hemen çıkma oranı, hangi tarayıcı ile giriş yapılmış, hangi şehirden giriş yapılmış, hangi arama kelimesi kullanılarak giriş yapılmış gibi birçok alan bulunmaktadır. Bu çalışmada, Google Analitiğin sunduğu bu alanlardan, bir sayfanın ana sayfada linkinin olmasını gerektirecek alanlar olan sayfa görüntüleme sayısı, tekil sayfa görüntüleme sayısı, sayfada geçirilen süre, giriş sayısı, çıkış oranı ve hemen çıkma oranı alanları kullanılmıştır. Sayfa görüntüleme sayısı, o sayfaya kaç kere girildiğini göstermektedir. Tekil sayfa görüntüleme sayısı, o sayfaya kullanıcı bazlı olarak girişi göstermektedir. Giriş sayısı, kullanıcının web sitesine ilk giriş yaptığı sayıdır. Örneğin kullanıcı A sayfasına giriş yapıp aynı site içerisinde B sayfasına geçiş yaparsa A sayfasının giriş sayısı değeri 1 artarken B sayfasının giriş sayısı değişmez. Hemen çıkma oranı, sitedeki tek sayfalık oturumlara denirken, çıkma oranında bir oturumda birden fazla sayfa gezerek çıkış işlemi bulunmaktadır.

## 2.9.Weka

Weka, veri madenciliği işlemleri için kullanılan, makine öğrenme algoritmalarını barındıran, Yeni Zelanda'daki Waikato Üniversitesindeki makine öğrenmesi grubu tarafından geliştirilmiş açık kaynak kodlu bir programdır. Weka ile veri madenciliği algoritmaları doğrudan bir veri kümesine uygulanabilmekte ya da geliştirilen java kodundan çağrılabilir. Weka programında, veri ön işleme, sınıflandırma, kümeleme, ilişkilendirme kuralları ve görselleştirme araçları bulunmaktadır. Ayrıca yeni makine öğrenme planları geliştirmek için de uygun bir programdır [23].

## 3.BULGULAR

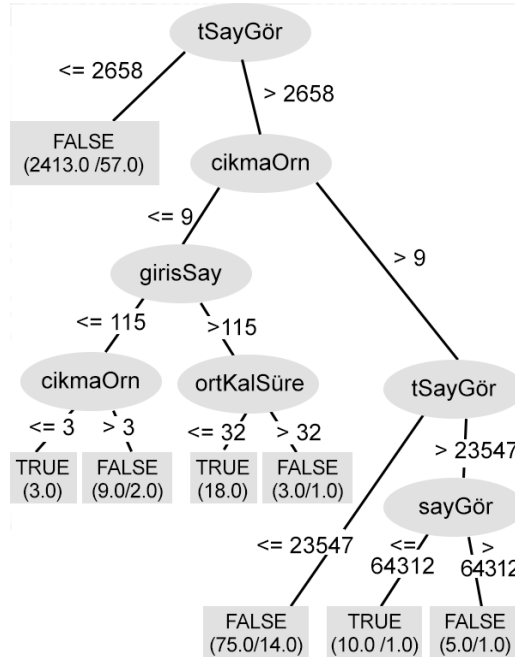
Karar ağaçları yönteminde sınıflandırılması istenilen veriler, sınıflandırma algoritmasına gönderilmekte ve sınıflandırma sonucunda bir karar ağacı oluşturulmaktadır. Oluşturulan karar ağacına göre sınıfı belli olmayan verilerin sınıflandırma işlemi gerçekleştirilmektedir.

**Tablo 3.** Algoritmaların Doğru Sınıflandırma Oranları

Algoritma	Doğru Sınıflandırma Oranı
C4.5	96.3722 %
Random	96.2934 %
REP Tree	96.2145 %
CART	96.1356 %
LMT	95.9779 %

Bu çalışmada yöntem kısmında bahsedilen veriler weka programı vasıtasıyla sınıflandırma algoritmalarından C4.5, Random Forest, REP Tree, Logistic Model Tree ve CART algoritmalarıyla sınıflandırılmıştır. Sınıflandırma işlemi sonucunda Tablo 3’de de görüldüğü gibi en yüksek sınıflandırma oranına C4.5 algoritması ulaşmıştır. En başarılı sınıflandırma işlemi C4.5 algoritması yaptığı için C4.5 algoritmasının karar ağacı oluşturulmuştur. Şekil 1’de bu karar ağacı gösterilmektedir. Bu karar ağacına bakılarak aşağıdaki karar kuralları oluşturulabilmektedir.

1. Tekil Sayfa Görüntüleme Sayısı  $\leq 2658$  ise Ana Sayfada Göster = False
2. Tekil Sayfa Görüntüleme  $> 2658$  ve Çıkma Oranı  $\leq 9$  ve Giriş Sayısı  $\leq 115$  ve Çıkma Oranı  $\leq 3$  ise Ana Sayfada Göster = True
3. Tekil Sayfa Görüntüleme  $> 2658$  ve Çıkma Oranı  $\leq 9$  ve Giriş Sayısı  $\leq 115$  ve Çıkma Oranı  $> 3$  ise Ana Sayfada Göster = False
4. Tekil Sayfa Görüntüleme  $> 2658$  ve Çıkma Oranı  $\leq 9$  ve Giriş Sayısı  $> 115$  ve Ortalama Sayfada Kalma Süresi  $\leq 32$  ise Ana Sayfada Göster = True
5. Tekil Sayfa Görüntüleme  $> 2658$  ve Çıkma Oranı  $\leq 9$  ve Giriş Sayısı  $> 115$  ve Ortalama Sayfada Kalma Süresi  $> 32$  ise Ana Sayfada Göster = False
6. Tekil Sayfa Görüntüleme  $> 2658$  ve Çıkma Oranı  $> 9$  ve Tekil Sayfa Görüntüleme Sayısı  $\leq 23547$  ise Ana Sayfada Göster = False
7. Tekil Sayfa Görüntüleme  $> 2658$  ve Çıkma Oranı  $> 9$  ve Tekil Sayfa Görüntüleme Sayısı  $> 23547$  ve Sayfa Görüntüleme Sayısı  $\leq 64312$  ise Ana Sayfada Göster = True
8. Tekil Sayfa Görüntüleme  $> 2658$  ve Çıkma Oranı  $> 9$  ve Tekil Sayfa Görüntüleme Sayısı  $> 23547$  ve Sayfa Görüntüleme Sayısı  $> 64312$  ise Ana Sayfada Göster = False

**Şekil 1.** Çalışma Sonucunda Oluşturulan Karar Ağacı



#### 4.TARTIŞMA VE SONUÇ

Weka programı birçok veri madenciliği yöntemini desteklemekte ve her bir yönteme ait pek çok algoritma ile analiz yapabilmektedir. Weka ile veri madenciliği algoritmaları doğrudan veri kümesine uygulanarak veri madenciliği işlemi gerçekleştirilebilmektedir. Bu çalışmada Artvin Çoruh Üniversitesinin web sitesine ait 2536 adet Google Analitik verisi weka programı kullanarak çeşitli sınıflandırma algoritmaları kullanılarak sınıflandırılmış ve en iyi sınıflandırma işlemi yapan algoritma kullanılarak 8 adet kural üreten bir karar ağacı oluşturulmuştur. Bu kurallar kullanılarak bir alt sayfanın linkinin ana sayfada bulunmasının gerekli olup olmadığı anlaşılabilir. Böylece web sitesinin ana sayfası, daha çok görüntüleme alan, sayfada kalma süresi yüksek olan, çıkma oranı düşük olan sayfaları barındırır ve web sitesini kullanan kullanıcılar için aradıkları bilgiye erişmeyi kolaylaştırır ayrıca web sitesinin daha fonksiyonel olması sağlanır.

Uygulama sonucuna bakılacak olursa, verilerin Google Analitikten alınıp weka programıyla veri madenciliği işlemine tabi tutulup, sonucunda karar ağacı üretilip ve bu karar ağacından karar kuralları üretmek oldukça zahmetli ve iş yükü gerektiren işlemlerden oluşmaktadır. Bu işlemlerin hepsi tek bir web tabanlı uygulama ile rahatlıkla gerçekleştirilebilir. Geliştirilecek web tabanlı uygulama Google Analitik servislerini kullanarak web sitesine ait verileri Google Analitikten çekebilir, çektiği verileri veri madenciliğine hazır hale getirdikten sonra bu uygulamada kullandığımız C4.5 algoritmasına göndererek karar ağacını oluşturabilir. Karar ağacını oluşturduktan sonra verilen linkin ana sayfada olup olmadığına karar verebilir. Böylece karar ağacı üretme ve link tespiti işlemi çok daha hızlı bir şekilde gerçekleştirilebilir.

Bu çalışmada bir web sitesinin ana sayfasında bulunması gereken öğeler veri madenciliği yöntemi ile belirlenmiştir. Ancak bu verilerin insan bilgisayar etkileşimi açısından da incelenmesi sonuçların genellenebilirliği açısından önem taşımaktadır. Ayrıca bu çalışma, ana sayfa linklerinin belirlenmesinden sonra kullanıcı temelli bir değerlendirme yaparak kullanıcıların memnuniyetinde bir değişiklik olup olmadığını araştırılması sonraki çalışmalara yön verme noktasında önem arz etmektedir.

#### KAYNAKLAR

- [1] Resul, D., İ. Türkoğlu, ve M. Poyraz, Bir Web Sitesine Ait Kullanıcı Erişim Kayıtlarının Web Kullanım Madenciliği Yöntemiyle Analizi: Fırat Üniversitesi Örneği. e-Journal of New World Sciences Academy 2008. 3(2).
- [2] Daş, R., İ. Türkoğlu, ve M. Poyraz, Web Kayıt Dosyalarından İlginç Örüntülerin Keşfedilmesi. Fırat Üniversitesi Fen ve Mühendislik Bilimleri Dergisi, 2007. 19(4): s. 493-503.
- [3] Tuğ, E., M. Şakiroğlu, and A. Arslan, Auto-matic discovery of the sequential accesses from web log data files via a genetic algorithm. Knowledge-Based Systems, 2006. 19(3): p. 180-186.
- [4] Carmona, C.J., et al., Web usage mining to improve the design of an e-commerce website: OrOliveSur. com. Expert Systems with Applications, 2012. 39(12): p. 11243-11249.
- [5] Parvatikar, S. and B. Joshi. Analysis of user behavior through web usage mining. in ICAST–International Conference on Advances in Science and Technology. 2014. Citeseer.
- [6] Özkan, Y., Veri madenciliği yöntemleri. 2008: Papatya Yayıncılık Eğitim.
- [7] Silahtaroglu, G., Veri madenciliği. Papatya Yayınları, İstanbul, 2008.
- [8] Alpaydın, E., Zeki veri madenciliği: Ham veriden altın bilgiye ulaşma yöntemleri. Bilişim 2000 eğitim semineri, 2000.
- [9] Han, J. and M. Kamber, Data mining: concepts and techniques (the Morgan Kaufmann Series in data management systems). 2000.
- [10] Akpınar, H., Veri tabanlarında bilgi keşfi ve veri madenciliği. İÜ İşletme Fakültesi Dergisi, 2000. 29(1): p. 1-22.
- [11] Shannon, C., A Mathematical Theory of Communication. The Bell System Technical Journal., 1948. 27.



- [12] Quinlan, J.R., C4. 5: programs for machine learning. 2014: Elsevier.
- [13] Quinlan, J.R., Simplifying decision trees. International Journal of ManMachine Studies, 1987. 27(3): p. 221-234.
- [14] Devasena, C.L. Comparative Analysis of Random Forest REP Tree and J48 Classifiers for Credit Risk Prediction. in International Con-ference on Communication, Computing and Information Technology (ICCCMIT-2014). 2015.
- [15] Kalmegh, S., Analysis of WEKA data mining algorithm REPTree, Simple CART and RandomTree for classification of Indian news. International Journal of Innovative Science, Engineering and Technology, 2015. 2(2): p. 438-46.
- [16] Srinivasan, D.B. and P. Mekala, Mining Social Networking Data for Classification Using REPTree. International Journal of Advance Research in Computer Science and Manage-ment Studies, 2014. 2(10).
- [17] Brownlee, J. Bagging and Random Forest Ensemble Algorithms for Machine Learning. 19.12.2017]; Available from: <https://machinelearningmastery.com/bagging-and-random-forest-ensemble-algorithms-for-machine-learning/>.
- [18] Breiman, L., Random forests. Machine learning, 2001. 45(1): p. 5-32.
- [19] Breiman, L., et al., Classification and regression trees. 1984: CRC press.
- [20] Logistic model tree. 19.12.2017]; Available from: [https://en.wikipedia.org/wiki/Logistic\\_model\\_tree](https://en.wikipedia.org/wiki/Logistic_model_tree).
- [21] Landwehr, N., M. Hall, and E. Frank, Logistic model trees. Machine learning, 2005. 59(1-2): p. 161-205.
- [22] Parmaksız, M.Y., Google Analytics. Dikeyksen Yayınevi, İstanbul, 2013.
- [23] Weka 3: Data Mining Software in Java. n.d. <http://www.cs.waikato.ac.nz/ml/weka/index.html>

# Destek Vektör Makineleri ile Fibromiyalji Sendromu Sınıflaması

Cemile Zontul, Emrullah Hayta, Metin Zontul, Ayça Taş, Yavuz Siliğ

## ÖZET

*Fibromiyalji sendromu (FMS), uzun süreli yaygın vücut ağrısı ve tanımlanmış kronik bir ağrı sendromudur. Fibromiyalji Sendromu tanısı konulması zor bir hastalıktır. Bu sebeple, genellikle FMS tanısı, hastaya gereksiz birçok tedavi uygulandıktan sonra, klinik muayene ve hastanın yakınmalarının değerlendirilmesi ile gecikmeli olarak konulur. Bu açıdan FMS teşhisini kolaylaştıracak bir karar destek sistemine ihtiyaç vardır. Bu çalışmada, 175 FSM hastası ve 176 sağlıklı kontrol bireyi olmak üzere toplam 351 bireye sorulan sorular ve deneysel veriler kullanılarak makine öğrenmesi yöntemlerinden Destek Vektör Makineleri ile FMS sınıflaması yapılmış ve yüzde 85 başarı elde edilmiştir.*

**Anahtar Kelimeler:** Fibromiyalji Sendromu, Destek Vektör Makineleri, Sınıflama, Sağlık Karar Destek Sistemi.

## ABSTRACT

*Fibromyalgia syndrome (FMS) is a long-term common body pain and a defined chronic pain syndrome. Fibromyalgia syndrome is a difficult disease to diagnose. For this reason, after many unnecessary treatments are applied to the patient, the diagnosis of FMS is usually delayed by clinical examination and evaluation of the patient's complaints. In this respect, there is a need for a decision support system that will facilitate the diagnosis of FMS. In this study, by using the questions asked 351 respondents, 175 FSM patients and 176 healthy control subjects and experimental data, FMS classification was performed with Support Vector Machines which is one of machine learning methods and 85% success was achieved.*

**Keywords:** Fibromyalgia Syndrome, Support Vector Machines, Classification, Health Decision Support System.

## Information of Author(s):

### Cemile Zontul

Cumhuriyet Üniversitesi, Tıp Fakültesi, Biyokimya Anabilim Dalı Sivas-Türkiye

### Emrullah Hayta

Cumhuriyet Üniversitesi, Tıp Fakültesi, Fizik Tedavi ve Rehabilitasyon Anabilim Dalı Sivas-Türkiye

### Metin Zontul

İstanbul Aydın Üniversitesi, Tıp Fakültesi, Fizik Tedavi ve Rehabilitasyon Anabilim Dalı Sivas-Türkiye

### Ayça Taş

Cumhuriyet Üniversitesi, Sağlık Bilimleri Fakültesi, Beslenme ve Diyetetik Bölümü, Sivas- Türkiye

### \*Yavuz Siliğ

Cumhuriyet Üniversitesi, Tıp Fakültesi, Biyokimya Anabilim Dalı Sivas-Türkiye

### \* Contact Author

**Address:** Prof. Dr. Yavuz Siliğ, Department of Biochemistry, Cumhuriyet University, Faculty of Medicine, Sivas, Turkey

**Telephone Number:** +90 346 219 10 10 Ext. 2134

**E-mail:** [ysilig@cumhuriyet.edu.tr](mailto:ysilig@cumhuriyet.edu.tr)

Submit Date: 23.11.2017

Accept Date: 28.12.2017

Publish Date: 29.12.2017



## 1.GİRİŞ

Fibromiyalji sendromu (FMS), uzun süreli yaygın vücut ağrısı ve tanımlanmış 18 spesifik bölgenin en az 11'inde hassasiyet ile karakterize kronik bir ağrı sendromudur. FMS, yorgunluk, uyku bozukluğu, somatik sendromlar, psikolojik bozukluklar, özürülük ve yaşam kalitesinde bozuklukla ilişkilidir [1]. Genel popülasyonda sıklığı %2,9–4,7 arasında bildirilmiştir ve kadınlarda erkeklere göre daha yaygındır [2]. FMS her yaş ve cinsiyette görülebilmekle birlikte genelde 40-60 yaş grubu kadınları etkilemektedir [3]. Cinsiyet ve ileri yaş FMS de risk faktörü oluşturmaktadır [4]. Yapılan çalışmalara göre, sosyoekonomik düzey ve eğitim düzeyi düştükçe FMS prevelansının arttığı görülmektedir [5]. Ayrıca travma sonrası stres bozuklukları, travmatik çocukluk dönemi, tekrarlayan fiziksel ve psikolojik travmalar, mükemmeliyetçi yaşam tarzı, mesleki sorunlar gibi stres faktörleri, obezite, genetik yatkınlık, kronik hastalıklar da FMS'nin görülme sıklığı artmaktadır [6]. Etiyolojisinde kas mikro-sirkülasyonun da bozulma, uyku bozuklukları, santral ağrı mekanizmalarında anormallikler, biyojenik aminlerin düzeylerinde azalma, beyin omurilik sıvısında P maddesi ve sinir büyüme faktörlerinde artış, basınç-ağrı eşliğinde düşme, immün ve otonomik fonksiyonlarda bozulma, fiziksel travma, genetik yatkınlık gibi faktörler rol oynamaktadır [1]. FMS'nin nöropatik ağrı olarak sınıflandırılması ve patofizyoloji ile bağlantısından dolayı giderek önem kazanmaktadır. Son zamanlarda yapılan çalışmalarda FMS görülme sıklığı, romatoidartrite kıyasla yaklaşık 8,5 kat fazla olduğu kaydedilmiştir [7, 8].

Fibromiyalji Sendromu tanısını konulması zor bir hastalıktır. Hastalığın tanısı için hiçbir özel tanı testi yoktur. FMS'de tüm laboratuvar tetkikleri normal çıkar. Manyetik Rezonans Görüntüleme (MRG) ve radyolojik değerlendirme ile FMS'de herhangi bir bulguya vermez. Genellikle FMS tanısı hastaya gereksiz birçok tedavi uygulandıktan sonra, klinik muayene ve hastanın yakınmalarının değerlendirilmesi ile geçikmeli olarak konulur. Klasik istatistiksel yöntemler ile yapılan sınıflama çalışmalarında sınıfı belirleyen değişkenlerin birbirinden tamamen bağımsız olduğu varsayılmaktadır. Halbuki gerçek hayatta FSM'yi etkileyen uykusuzluk ve sabah yorgunluğu gibi değişkenler arasında bir ilişki olduğu açıktır. Bu sebeple, sınıf değişkenini etkileyen değişkenler arasında bağımsızlık varsayımı olmayan makine öğrenmesi yöntemleri ile FMS hastalarının verilerinin değerlendirilerek yüksek doğruluk oranları ile sonuçların kıyaslanması, hastalığın tanısı ve tedavisi açısından daha hızlı sonuca gitmeyi sağlayabilir. Literatürde makine öğrenmesi yöntemleri ile FMS teşhisi konusunda birçok çalışma mevcuttur.

Bu çalışmaların birinde, Robinson ve arkadaşları (2015), 14 FMS'li ve 12 sağlıklı kontrol bireyi üzerinde makine öğrenmesi yöntemleri ile FMS sınıflaması yapmıştır. Yaptıkları çalışmada, 26 kişiye ait beyin MR görüntüleri ve görsel analog skala kullanılarak elde edilen ağrı yoğunluğu ile ruh hali ile ilgili kişisel puanlama verilerini kullanmışlardır[9]. Kişisel puanlama verileri ile yapılan sınıflamaların beyin görüntüleri ile yapılanlara göre daha başarılı olduğunu belirtmektedirler.

Diğer bir çalışmada, çoğunlukla karıştırılan FMS ve CFS ağrı sendromlarının sınıflaması makine öğrenmesi ile beyin MR görüntüleri ve görsel analog skala verileri kullanılarak yapılmış ve bu sendromların karşılaştırılması verilmiştir [10]. FMS ve CFS hastalarının ayrıştırılmasında MR görüntülerinin daha iyi sonuç verdiği belirtilmektedir.

Katz ve arkadaşları (2010) bir çalışmalarında, FMS teşhisinde cinsiyet etkisini makine öğrenmesi yöntemlerinden Random Forest algoritması ile incelemiştir. Araştırmacılar, FMS'li 39 erkek ve 22 kadın hastayı rasgele romatolojistlere atamış ve hasta öyküsünü gözönüne alarak hangi kriterlerin teşhiste daha önemli olduğunu uzmanlara sormuşlardır [11]. Sonuç olarak, uzmanların erkek hastalarda fiziksel bulgular üzerinde daha çok durduğunu tespit etmişlerdir.

Cinsiyet ve kan değerleri ile FSM arasında ilişki arayan çalışmalar da mevcuttur. Kadın hastaların günlük sikotin protein dalgalanmaları ile düşük ağırlı ve yüksek ağırlı FMS arasında bir ilişki olduğu Stringer ve arkadaşları (2013) tarafından makine öğrenmesi yöntemlerinden Destek Vektör Makineleri kullanılarak tespit edilmiştir. Günlük sikotin dalgalanmalarının FSM şiddetini artırabileceği belirtilmektedir [12].

Bu çalışmada, nöropatik ağrılardan biri olan FMS ile bu sendroma etki eden faktörler arasındaki ilişki makine öğrenmesi yöntemlerinden Destek Vektör Makineleri ile belirlenmeye çalışılmıştır. 175 FSM hastası ve 176 sağlıklı kontrol bireyi olmak üzere toplam 351 bireye sorulan sorular ve deneysel veriler birleştirilerek FSM'yi etkileyen 15 değişken belirlenmiştir. Makine öğrenmesi yöntemlerinden Destek Vektör Makineleri kullanılarak sınıflama yapılmış ve yüzde 85 başarı elde edilmiştir.

## 2.YÖNTEM

### 2.1.Verilerin Elde Edilmesi

Bu çalışmada, hasta grubu Eylül 2015 ve Eylül 2016 tarihleri arasında, Cumhuriyet Üniversitesi, Tıp Fakültesi, Fiziksel Tıp ve Rehabilitasyon Anabilimdalı ve Sivas Numune Hastanesi, Fizik Tedavi Kliniği'nde Fibromiyalji tanısı konan 175 hastadan oluşturuldu. Kontrol grubu ise yine aynı hastanelere başvuran, yaş ve cinsiyet açısından seçilen hasta grubuna benzer olacak şekilde Fibromiyalji tanısı konulmamış 176 sağlıklı bireyden oluşturulmuştur. Çalışmaya dahil edilen tüm hasta ve kontrollerle yüz yüze görüşülerek kendilerine yöneltilen soruları cevaplamaları istendi. Bu sorulara verdikleri yanıtlar ve deneysel veriler kullanılarak FMS ile bu sendromu etki eden faktörler arasındaki ilişki Destek Vektör Makineleri ile analiz edildi. Fibromiyalji hastaları ve kontrollerin demografik özellikleri Tablo 1'de verilmiştir. Ayrıca, kan testleri ile elde edilen rs4148855 ve rs2288646 genlerinin var olup olmadığı bilgisi de verilere ilave edilmiştir.

**Tablo 1:** Hastaların ve kontrollerin özellikleri

	<b>Kontrol n (%)</b>	<b>Fibromiyalji n(%)</b>
<b>Birey sayısı</b>	176	175
<b>Cinsiyet</b>		
Erkek	10 (5,1)	10 (5,7)
Kadın	166 (94,9)	165 (94,3)
<b>Yaş</b>		
Aralık	22-61	20-62
<b>Yaş Ort.</b>		
Erkek	39,69±17,27	40,33±16,30
Kadın	44,05±8,87	43,89±9,76
<b>Uyku Bozukluğu</b>		
Var	71 (40,4)	130 (74,2)
Erkek	2 (2,80)	6 (4,60)
Kadın	69 (97,2)	124 (95,4)
<b>Yorgunluk</b>		
Var	142 (81,1)	169 (96,5)
Erkek	6 (4,20)	10 (5,90)
Kadın	136 (95,8)	159 (94,1)
<b>Baş ağrısı</b>		
Var	100 (56,8)	146 (83,4)
Erkek	2 (2,00)	8 (5,50)
Kadın	98 (98,0)	138 (94,5)
<b>Sabah Yorgunluğu</b>		
Var	99 (56,5)	165 (94,2)
Erkek	4 (4,10)	10 (6,10)
Kadın	95 (95,9)	155 (93,9)
<b>Ağız kuruluğu</b>		
Var	91 (52,0)	132 (75,4)
Erkek	1 (1,10)	7 (5,30)
Kadın	90 (98,9)	125 (94,7)
<b>Bacak Uyuşması</b>		

Var	79 (44,8)	131 (74,8)
Erkek	1 (1,30)	4 (3,10)
Kadın	78 (98,7)	127 (96,9)
<b>Göz kuruluğu</b>		
Var	47 (26,8)	80 (45,7)
Erkek	1 (2,10)	4 (5,00)
Kadın	46 (97,9)	76 (95,0)
<b>Konsantrasyon Güçlüğü</b>		
Var	89 (50,6)	143 (81,7)
Erkek	3 (3,40)	3 (2,10)
Kadın	86 (96,6)	140 (97,9)
<b>Yumuşak dokularda şişkinlik</b>		
Var	74 (42,2)	116 (66,2)
Erkek	2 (2,70)	3 (2,60)
Kadın	72 (97,3)	113 (97,4)
<b>Ailede Fibromiyalji Öyküsü</b>		
Var	0 (0,0)	78 (44,5)
Erkek	0 (0,0)	3 (3,90)
Kadın	0 (0,0)	75 (96,1)

## 2.2.Verinin Ön İşlemesi

175 hasta ve 176 sağlıklı kontrol grubuna ait olan veriler birleştirilerek 351 satır ve 16 sütundan oluşan veri seti oluşturuldu. İlk 15 sütun Fibromiyalji Sendromunu etkileyen değişkenler 16. Sütun ise sınıf değişkeni (1: fibromiyalji var 2: fibromiyalji yok) olarak alındı. Değişkenlerin farklı aritmetik ortalama ve standart sapmaya sahip olmasından dolayı ilk 15 değişken z-skör yöntemi (mean=0, std=1) ile normalleştirildi. Sınıf değişkeni ikili sınıflama işleminin hedef değişkeni olduğu için normalleştirilmeden tam sayı olarak bırakıldı. Normalleştirme işlemi için Python sklearn.preprocessing kütüphanesinin scale metodu kullanılmıştır.

## 2.3.Değişkenlerin önem seviyeleri

Sınıflamayı etkileyen değişkenlerin önem seviyeleri Python sklearn.ensemble kütüphanesindeki *ExtraTreesClassifier* yöntemi ile belirlenmiştir. Önem seviyesi 0.01 ve üzerinde olan değişkenler modele katılmıştır.

## 2.4.Sınıflama Model Seçimi

Klasik istatistiksel yöntemlerde (lojistik regresyon vb) sınıf değişkenini etkileyen diğer değişkenlerin birbirinden tamamen bağımsız olduğu varsayılırken makine öğrenmesi yöntemlerinde (SVM, MLP, RandomForest vb) bu değişkenler arasında da bir ilişki olabilmesi sorun yaratmamaktadır. Bu sebeple, sınıflama işleminde makine öğrenmesi daha sağlıklı sonuç verebilmektedir. Ancak, Makine öğrenmesi sınıflama modellerinin eğitilmesi gerekmektedir. Bu sebeple, eldeki veri seti rastgele satır seçimi yaparak yüzde 67 eğitim verisi yüzde 33 test verisi olarak ayrılmıştır. Birçok makine öğrenmesi yöntemi arasında Destek Vektör Makineleri (SVM) yöntemi en iyi sonucu vermiştir. Bu işlem Python sklearn.svm kütüphanesinin SVC metodu ile gerçekleştirilmiştir. Sklearn. Model- selection kütüphanesinin Cross-Validation yöntemi ile de veri seti 10 parçaya ayrılarak da test yapılmış sonucun pek değişmediği gözlenmiştir.

### 3.BULGULAR

ExtraTreesClassifier yöntemi ile elde edilen fibromiyalji sınıf tahminini etkileyen değişkenler ve önem seviyeleri Tablo 2’de verilmiştir. Bu değişkenler içinde en etkili olanların Yaş, Sabah Yorgunluğu ve Ailede Fibromiyalji Öyküsü olduğu gözlenmektedir.

**Tablo 2:** Fibromiyalji sınıf tahminini etkileyen değişkenler ve önem seviyeleri

Değişken	Önem Seviyesi
rs4148855	0.0656792241051
rs2288646	0.00729977771732
Cinsiyet	0.0119939589481
Yaş	0.19099113329
Meslek	0.0400881050249
Uyku Bozukluğu	0.0739067125275
Yorgunluk	0.0325649866472
Baş ağrısı	0.0570267801751
Sabah Yorgunluğu	0.108242620237
Ağız kuruluğu	0.0277203314353
Bacak Uyuşması	0.0533385792451
Göz kuruluğu	0.035869288009
Konsantrasyon Güçlüğü	0.0705225525429
Yumuşak dokularda şişkinlik	0.0407905856243
Ailede Fibromiyalji Öyküsü	0.183965364471

Destek Vektör Makineleri yöntemi ile elde edilen sınıflama değerleri Tablo 3 ve Tablo 4’te verilmiştir. Test verisi olarak her iki sınıftan 58 şer veri kullanılmıştır. Tablo 3’te verilen karışıklık matrisine bakıldığında, 58 Fibromiyalji hastasının 53’ü doğru tahmin edilmiştir. Fibromiyalji olmayan 12 hastanın Fibromiyalji sınıfına yanlış yerleştirildiği görülmektedir. Hastalık ile ilgili sınıflamalarda TP (53) değerlerinin TN (46) değerlerinden yüksek olması hastalık teşhisi açısından önem arz etmektedir. Tablo 4’de gözüktüğü gibi, farklı sınıflama metriklerine göre de sonuçlar tutarlı olup ortalama yüzde 85 başarı elde edilmiştir.

**Tablo 3:** Karışıklık Matris Değerleri.

Sınıflar	Fibromiyalji Var	Fibromiyalji Yok
Fibromiyalji Var	53 (TP)	5 (FN)
Fibromiyalji Yok	12 (FP)	46 (TN)

**Tablo 4:** Destek Vektör Makineleri yöntemi ile Fibromiyalji sınıflama skorları

Sınıf	precision	recall	f1-score	support
Fibromiyalji Var	0.82	0.91	0.86	58
Fibromiyalji Yok	0.90	0.79	0.84	58
Ortalama/Toplam	0.86	0.85	0.85	116

#### 4.TARTIŞMA ve SONUÇ

Bu çalışmada, 175 FMS hastası ve 176 sağlıklı birey ile yüz yüze görüşerek sorulan sorulara alınan yanıtlar ve ilgili bireylerin kan testlerinden elde edilen 2 gen değeri ile veri seti oluşturulmuştur. Veri setinin 1 sınıf değişkeni (Fibromiyalji Var/Yok) ve sınıflamayı etkilediği düşünülen 15 özellik değişkeni bulunmaktadır. Değişkenler ile FMS arasındaki ilişki makine öğrenmesi yöntemlerinden Destek Vektör Makineleri ile sınıflama yapmak suretiyle belirlenmeye çalışılmıştır.

Veri setinin normalleştirilmesi, özellik seçimi ve sınıflama işlemleri için Python sklearn kütüphanesi kullanılmıştır. Sınıflamayı en çok etkileyen özellik değişkenlerinin Yaş, Sabah Yorgunluğu ve Ailede Fibromiyalji Öyküsü olduğu tespit edilmiştir. Destek Vektör Makineleri yöntemi ile yapılan sınıflama sonucunda elde edilen karışıklık matrisi (Confusion Matix) ve sınıflama metrikleri tutarlı olup ortalama yüzde 85 doğrulukta fibromiyalji sınıf tahmini gerçekleştirilmiştir. Ayrıca, karışıklık matrisindeki TP değerinin TN değerinden yüksek olması FMS teşhisi açısından daha anlamlıdır. Böylece, daha az hasta FMS tedavisinden mahrum kalmaktadır.

İleriki çalışmalarda, fibromiyalji sınıflamasının başarı değerini artırmak için çeşitli kan değerleri ve beyin görüntüleri veri setine ilave edilerek makine öğrenmesi yöntemleri hibrit bir şekilde denenebilir. Ayrıca, oluşturulan modeller, sağlık karar destek sistemleri oluşturmak amacıyla daha çok veri üstünde daha çok hastalığın teşhisi için kullanılabilir.

#### TEŞEKKÜR

Bu araştırma, Cumhuriyet Üniversitesi tarafından CÜBAP T-656 numaralı proje ile desteklenmiştir.

#### KAYNAKLAR

- [1] Adler, G.K. Manfredsdottir V.F., and Creskoff K.W. 2002 "Neuroendocrine abnormalities in fibromyalgia".Current pain and headache reports. 6: 289-298.
- [2] Marcus, DA. A Primary Care Guide to Practical Management. In Chronic Pain pp 15-30. PA Human Pres. Pain Institute, University of Pittsburgh, Pittsburgh.2005 .
- [3] Yılmaz, H. Uğurlu H., and Sallı A. 2007 "Fibromiyalji Sendromlu Hastalarda Kas Performansı".Romatizma/Rheumatism. 22.
- [4] McBeth J. and Jones K. 2007 "Epidemiology of chronic musculoskeletal pain".Best practice & research Clinical rheumatology. 21: 403-425.
- [5] Guleç, H. Sayar K., and Guleç M.Y. 2007 "The Relationship Between Psychological Factors and Health Care-Seeking Behavior in Fibromyalgia Patients".
- [6] Neumann L. and Buskila D. 2003 "Epidemiology of fibromyalgia".Current pain and headache reports. 7: 362-368.
- [7] Buskila, D. et al., Familial aggregation in the fibromyalgia syndrome, in *Seminars in arthritis and rheumatism*. Elsevier, 1996 605-611.

- [8] Kato, K. et al. 2006 "Importance of genetic influences on chronic widespread pain". *Arthritis & Rheumatology*. 54: 1682-1686.
- [9] Robinson, M.E. et al. 2015 "Comparison of machine classification algorithms for fibromyalgia: neuroimages versus self-report". *The Journal of Pain*. 16: 472-477.
- [10] Sevel, L. et al. 2016 "MRI based classification of chronic fatigue, fibromyalgia patients and healthy controls using machine learning algorithms: a comparison study". *The Journal of Pain*. 17: S60.
- [11] Katz, J.D. et al. 2010 "Gender bias in diagnosing fibromyalgia". *Gender medicine*. 7: 19-27.
- [12] Stringer, E. et al. 2013 "Daily cytokine fluctuations distinguish high pain from low pain days in women with fibromyalgia". *The Journal of Pain*. 14: S50.



# Ecosystem Effects of the Industrial Internet of Things on Manufacturing Companies

Christian ARNOLD, Kai-Ingo VOIGT

## ABSTRACT

*The Industrial Internet of Things (IIoT) represents a novel, future-oriented paradigm of industrial value creation, which facilitates the creation of networks across and within manufacturing companies. Consequently, the IIoT is associated with an adjusted characterization of respective business ecosystems. As current research has primarily focused on the IIoT's technical fundamentals, economic research is still in its infancy. This article aims at examining the effects of IIoT on manufacturing companies' business ecosystems by applying a mixed-method approach. Thus, we carried out a quantitative survey among 198 German manufacturers from several industries based on insights of 15 expert interviews. This study contributes to the sparse body of scientific IIoT literature from an economic perspective by revealing that IIoT adoption is associated with greater openness of manufacturers toward participants of all analyzed ecosystem dimensions, i.e., customers, suppliers, organizations external to the own industry, and research institutions. Moreover, an intensified ecosystem integration is expected over time..*

**Keywords:** Industry 4.0, Industrial Internet of Things, Business ecosystem, Manufacturing companies, Mixed method.

## Information of Author(s):

\* **Christian ARNOLD**  
christian.arnold@fau.de  
Friedrich-Alexander University Erlangen-Nürnberg

**Kai-Ingo VOIGT**  
Friedrich-Alexander University Erlangen-Nürnberg

\* **Contact Author**

Submit Date: 21.11.2017  
Accept Date: 22.12.2017  
Publish Date: 29.12.2017



## 1. INTRODUCTION

The Industrial Internet of Things (IIoT) represents a novel, future-oriented paradigm of industrial value creation. At its core, it represents the proceeding digitized connection of industrial manufacturing based on the application of cyber-physical systems (CPS). They enable the connection of the physical and the virtual world and therefore facilitate the creation of networks across and within manufacturing companies (Frazzon et al., 2013). In addition, machines, products, and entire buildings are equipped with embedded systems like actuators, sensors, and microcomputers providing them with intelligence. This results in the “real-time capable, intelligent, horizontal, and vertical connection of people, machines, objects, and ICT systems to dynamically manage complex systems” (Bauer et al., 2014, p. 18). In the final vision, smart factories allow the autonomous and flexible guidance of products through entire value chains. Furthermore, machines are able to automatically set-up and to reschedule the production on their own in the case of an error. Consequently, this visionary production approach enables a flexible and efficient execution of production and offers the potential for resolving recent challenges for manufacturers like shortened technology and innovation cycles, batch-size-one production at the cost of a large-scale production, and intensified competition originating particularly in Asia (Bauer et al., 2014; Dais, 2014). In parallel, IIoT business ecosystems emerge due to the IIoT-inherent networking possibilities. They involve companies in different roles, e.g., module providers, machine-to-machine service providers, network operators, and users that interact and share connected hardware, software, and platforms among each other (Iansiti & Levien, 2004; Mazhelis et al., 2012).

To date, scholars have primarily focused on technological prerequisites, fundamentals, and challenges (Brettel et al., 2014; Kiel et al., 2016). Equally important, but still in its infancy, is economic research with regard to the IIoT. Although there are some works that deal with economic topics such as human resource management (e.g., Bonekamp & Sure, 2015; Nagar & Raj, 2013) and business models (e.g., Arnold et al., 2016; Kiel et al., 2016), scientific studies examining the effect of the IIoT on companies’ business ecosystems and relations to partners are still very scarce. The term “ecosystem” has its origin in biology and refers to a “community of organisms, interacting with one another, plus the environment in which they live and with which they also interact” (Moore, 1997, p. 26). In the business context, an ecosystem comprises actors within a company, the value chain, and the entire market, and describes the interrelationships among these actors (Mazhelis et al., 2012). Correspondent to the biological analogy, a business ecosystem is composed of a multitude of actors, which act separately but depend on each other through common interests (Iansiti & Levien, 2004). Business ecosystems are furthermore characterized by dynamic connections, which can be established and cut according to recent developments (Peltoniemi & Vuori, 2004).

The absence of scientific work on this perspective in the context of IIoT effects is somewhat surprising, as the IIoT aims at connecting all supply chain participants, which necessitates a linkage of various organizations in new ways (Obermaier, 2016). Moreover, triggered by CPS, business ecosystems will supersede traditional linear value chains (Geisberger & Broy, 2012). Consequently, we address this research gap by dedicating ourselves to the following research question: How does the IIoT affect the business ecosystems of manufacturing companies?

A review of relevant contributions related to our research question identified only a few studies that contain IIoT-driven business ecosystem effects. In their work, Weill and Woerner (2015) identified so-called ecosystem drivers, which establish a joint platform with other companies in order to serve their own customers with complementary products and services. Eloranta and Turunen (2016) examined how companies leverage network-related complexity in their operations. It has been found that in particular, platforms that enable increasing ties with suppliers lead to an enhanced value added. Furthermore, the authors argue that platforms facilitate the collection of information within the ecosystem and blur company boundaries, resulting in a greater importance of the ecosystem as a whole in relation to the single ecosystem participants. Berman and Korsten (2014) also reveal that increasing digitization and associated interconnectedness blur company boundaries. Consequently, ecosystem actors jointly employ assets like data and resources.

## **2. METHODS**

Based on the sparse body of extant literature and the absence of academic studies that address the effects of the IIoT on the ecosystems of manufacturing companies, in particular, we decided to apply a mixed-method approach. This is a combination of qualitative and quantitative research techniques and methods, which are applied in one single study (Johnson & Onwuegbuzie, 2004). Such an approach is particularly suitable for gaining a comprehensive understanding of complex technological, organizational, and social phenomena, like with the IIoT (Venkatesh et al., 2013). Following the most prevalent mixed-method approach, we applied a sequential study (Creswell & Plano Clark, 2011).

In a first step, we conducted qualitative expert interviews with 15 German companies operating in the electronic engineering and machine and plant engineering sectors. By doing so, we aimed at confirming IIoT-triggered effects on business ecosystems addressed in the sparse existing literature and identifying additional effects experienced by the interviewed companies (Engelken et al., 2016). Secondly, we carried out a quantitative survey among 198 German manufacturing companies in order to test the propositions based on literature and the expert interviews' results (Engelken et al., 2016).

## **3. EXPERT INTERVIEWS**

We conducted 15 semi-structured expert interviews with knowledgeable and experienced managers of German electrical engineering and machine and plant engineering companies. We chose manufacturers from these two industries because the former represents crucial suppliers of necessary technological foundations for the IIoT (Atzori et al., 2010) and the latter are supposed to be among the major beneficiaries of this new production paradigm, as the machine and plant engineering sector represents the largest among all German industrial sectors (Federal Bureau of Statistics, 2016). Hence, we argue that companies operating in these two industries are among the first to experience IIoT-specific business ecosystem changes. Moreover, statements made by experts from electrical engineering companies serve to verify and supplement machine and plant engineering companies' statements with regard to suppliers. The interviewed informants had to be reliable and knowledgeable experts. Therefore, they had to possess a middle or top management position, relevant technical and business knowledge, and know the companies' ecosystems and other environmental influences well. We contacted 99 companies, of which we interviewed 15 companies of different sizes that had already gained experience with the IIoT in their own production; seven originating in the machine and plant engineering sector and eight originating in the electrical engineering sector. All interviews were conducted between March and May 2016.

The interviews were audio-recorded, transcribed, and analyzed according to the qualitative content analysis (Miles & Huberman, 1994). The developed categories were informed by extant literature but defined inductively (Kelley et al., 2009) in order to allow concepts to emerge from this process (Graebner & Eisenhardt, 2004). For the coding and analysis process, we followed the scientifically recognized and recommended work of Gioia et al. (2013). According to them, the first step is to perform an initial data coding, which maintains the integrity of first-order (informant-centric) concepts. The first author of the paper at hand provided the initial data coding, which was discussed afterwards in team, resulting in consistently checked and revised categories. In a second step, we organized the first-order concepts into second-order themes. Against the background of our research goals, these second-order themes were inspired by our previous knowledge based on having consulted literature. The findings of the expert interviews enabled us to develop propositions with reference to business ecosystem changes due to the IIoT, which were subsequently tested by applying a quantitative survey.

## **4. QUANTITATIVE STUDY**

For our quantitative data analysis, we conducted a cross-sectional field survey to collect data about IIoT effects on business ecosystems of German manufacturing companies. The German market was chosen since the term 'IIoT', in its German equivalent 'Industrie 4.0', originally appeared in Germany and the German manufacturing industry is a global leader and has always been a pioneer in terms of implementing innovative technologies (Breznitz, 2014). Additionally, the manufacturing sector is the most important one for the German economy in terms of

employees and contribution to the GDP (Federal Bureau of Statistics, 2016), which justifies our examining of manufacturers in particular.

German manufacturers were identified by consulting the bisnode database, which lists German companies from all industries and sizes. We contacted appropriate companies via e-mail and telephone and gave them access to an online questionnaire between January and March 2017. Referring to the procedure described by Kurniawan (2008), this questionnaire is based on the expert interviews' results and consists of closed-ended questions. Section A contains questions about company demographics, followed by a dichotomous question about whether the company has already adopted the IIoT or not. If not, they were asked if an adoption is planned in the medium term. Section B comprises questions regarding the items measuring the proposed ecosystem changes. They all consist of a Likert-Scale from 1 (strongly disagree) to 5 (strongly agree). Section C deals with respondent's personal data.

To assure comprehensibility and content validity, ten companies participated in a pilot test of the survey (Cooper & Schindler, 1998). Feedback resulted in minor adjustments of the questionnaire and the final survey link was sent to 2,750 German manufacturing companies. As a result, we received 362 questionnaires, representing a response rate of 13.2%. After a data-cleaning procedure, which eliminated incomplete values, a total of 198 usable questionnaires was left, constituting a final 7.2% response rate. In order to account for a potential non-response bias (Fowler, 1993), we compared data between early and late respondents. Therefore, we employed size in terms of revenues and four randomly selected items. The results of the Mann-Whitney test shows no significant difference between early and late respondents, indicating the absence of non-response bias (Ramsey et al., 2008).

## **5. FINDINGS**

### **5.1. Expert Interview Results**

Most of the interviewed machine and plant engineering companies reported on various IIoT-driven changes regarding their customers. They increasingly face customers who are unsure about potential benefits of IIoT-ready facilities. Therefore, they increasingly engage in consultation activities. If the customers were already aware of the IIoT, the interviewed companies extended exchange of information and knowledge and intensified joint technology and product development. By doing so, they aim at ensuring that new products meet changing customer requirements. In addition to pure development activities, some interviewees reported on joint production activities with customers. Therefore, the end customer is directly integrated into the production process. Consequently, we deduce the following proposition regarding IIoT-driven ecosystem changes in terms of customers:

Proposition 1. Manufacturing companies that have already implemented the IIoT into their production perform more customer consultation activities, exchange more information with customers, conduct more intensely joint developments with customers, and integrate customers more into their own production processes than do manufacturers without any IIoT experience.

Taking a look on the other side of the supply chain, a similar picture emerges regarding manufacturer's suppliers. Machine and plant engineering companies do not only advise customers with reference to the IIoT, but also draw on consultations themselves. Additionally, they increasingly exchange knowledge with their suppliers. This is confirmed by the experts who originate in electrical engineering companies reporting on a rising need for expert advice by machine and plant engineering companies, particularly in terms of potential benefits of the IIoT or how to connect machines to the internet. Machine and plant engineering companies further conduct joint development activities with suppliers, especially with sensor suppliers. The aim of such development cooperation is a target-oriented advancement of sensors required for specific IIoT applications as well as to ensure compatibility of components obtained by several suppliers that have to work in combination. Although stated by only one expert originating in the machine and plant engineering industry, those companies seem to be increasingly integrated with the production of electrical equipment suppliers, as this is also stated by some electrical engineering companies. Due to the above-outlined expert statements, we deduce the following proposition regarding supplier-related ecosystem changes:

Proposition 2. Manufacturing companies that have already implemented the IIoT into their production demand more supplier consultations, exchange more information with suppliers, conduct more intensive joint developments with suppliers, and are integrated more into their suppliers' production processes than are manufacturers without any IIoT experience.

The expert statements indicate that not only are suppliers and customers, i.e., direct value chain partners, important entities in future production, but also organizations external to the traditional value chain. They increasingly utilize knowledge from outside their own industry. In this context, they state, for example, IT enterprises being consulted regarding data analyses or consultancy agencies in terms of future IIoT application fields and required hardware. Further, machine and plant engineering companies start to cooperate with competitors in order to offer a joint product portfolio that is more powerful than the solution of one company alone. The interview results also show the particular importance of research institutions like universities since nearly all experts made statements about a respective knowledge transfer. To be more precise, they draw on know-how developed by such institutions. Additionally, most of them conduct joint development activities with universities and similar institutions. Therefore, we consider the emphasis of research institutions and deduce the following two propositions:

Proposition 3. Manufacturing companies that have already implemented the IIoT into their production more strongly draw on knowledge from outside their industry sector and offer a larger joint portfolio in cooperation with competitors than do manufacturers without any IIoT experience.

Proposition 4. Manufacturing companies that have already implemented the IIoT into their production exchange more knowledge with research institutions and conduct more intensive joint developments with research institutions than manufacturers without any IIoT experience.

In addition to the aforementioned four propositions, we expect that IIoT-related business ecosystem changes will be further intensified in the future, as we are just on the threshold of the IIoT. Thus, manufacturers just started to implement this new production approach into their value creation and modify their business ecosystems. Furthermore, it is arguable that companies that have already implemented the IIoT are more poised to further open toward their business ecosystem than those companies that have not yet dealt with the IIoT. Therefore, we add the following proposition:

Proposition 5. Manufacturing companies that have already implemented the IIoT into their production will experience stronger business ecosystem changes in future than manufacturers without any IIoT experience.

## 5.2. Quantitative Survey Results

Survey results show that the majority of the respondents are at least senior managers (64.8%) and are well-educated (84.4% hold at least a university degree). Referring to company data, most respondents operate in the machine and plant engineering sector (33.5%), followed by metal processing (14.4%) and electrical equipment (11.9%). Table 1 summarizes the demographics of the sample.

Regarding IIoT implementation, data show that 23.2% have already adopted it. Among non-adopters, 55.3% have plans to implement the IIoT in the medium term. As we are still at the threshold of this new production paradigm, it is reasonable to consider intent to adopt in addition to actual adoption (Vowles et al., 2011). Consequently, 65.7% of the sample at least intend to adopt the IIoT in the mid-term future.

Based on the expert interviews and referring to proposition 1, the companies were asked to assess the IIoT's effects in terms of comprehensively consulting customers, excessively exchanging information with customers, integrating customers into their own production processes, and conducting comprehensive, joint development activities. A Mann-Whitney test resulted in highly significant differences between companies intending to adopt or already adopted the IIoT (hereinafter referred to as adopters) and those companies without an intention to implement the IIoT in the medium term (hereinafter referred to as non-adopters).

**Table 1.** Demographics of respondents (n = 198)

Variables	Frequency	Variables	Frequency
Revenues (in million EUR)		IIoT adoption	
0-10	33.0%	IIoT adopted	23.2%
10-50	29.8%	IIoT not adopted	76.8%
50-100	10.5%	Educational level	
100-250	6.8%	Apprenticeship	14.5%
250-500	4.2%	University degree	74.7%
500-1,000	1.6%	PhD degree	9.7%
1,000-5,000	4.2%	Other	1.1%
5,000-10,000	0.5%	Job position	
10,000-50,000	4.7%	Executive board	15.1%
>50,000	4.7%	Top management	23.2%
Industry sector		Senior management	26.5%
Machine and plant engineering	33.5%	Middle management	15.7%
Metal products	14.4%	Employees with managerial responsibility	8.1%
Electrical equipment	11.9%	Employees without managerial responsibility	11.4%
Electronics	10.8%		
Automotive	9.3%		
Chemical products	5.2%		
Rubber & plastics	4.6%		
Other	10.3%		

As Table 2 shows, today’s mean value of all four items is at least 2.15 among adopters, while non-adopters show an average manifestation of 1.88 at most. This indicates that manufacturers already dealing with the IIoT are more open toward customers than non-adopters, although they still do not experience strong IIoT-driven ecosystem effects regarding their customers. This picture is confirmed when comparing the median of each item between adopters and non-adopters, which is more robust against single outliers (Müller, 2000). Regarding all customer aspects except information exchange, the median of the responses referring to today’s evaluation is 2 among adopters. Information exchange is the only item with a medium assessment, expressed by a median of 3. In comparison, the median for all four customer aspects is 1 among non-adopters. Hence, the majority of those companies strongly disagrees with having any customer contact beyond pure product selling. This indicates that the implementation of the IIoT comes along with a more open and intensified relation toward the customer perspective of a company’s business ecosystem, albeit at a rather low level. Hence, proposition 1 is supported.

**Table 2.** Results with regard to a business ecosystem’s customer dimension

		today		medium term	
		mean	median	mean	median
customer consultations	adopters	2.47	2	2.98	3
	non-adopters	1.81	1	2.28	2
information exchange	adopters	2.72	3	3.36	3
	non-adopters	1.82	1	2.29	2
integration into own production process	adopters	2.15	2	2.92	3
	non-adopters	1.54	1	1.82	1
joint development activities	adopters	2.45	2	2.98	3
	non-adopters	1.88	1	2.25	2

With regard to our second proposition dealing with suppliers, the companies were requested to evaluate to what extent IIoT adoption leads to the utilization of comprehensive consultations by suppliers, excessive information exchange with suppliers, an integration into suppliers’ production processes, and comprehensive, joint development activities with suppliers. A Mann-Whitney test again resulted in highly significant differences between adopters and non-adopters. Taking a look at the mean value of each item reveals a similar picture as for the customer side. Again, this is supported by the median values since all items have a median of 2 for today’s assessment among adopters, while all non-adopters show a median of 1, as illustrated in Table 3. This is a



difference at a rather low level, but adopters seem to maintain at least some connection to their suppliers. In contrast, more than half of all non-adopters strongly disagree to have a connection to their suppliers beyond obtaining products. This indicates that, at a very low level, IIoT implementation is associated with a more open and intensified relation toward suppliers as part of the business ecosystem. Thus, proposition 2 is supported.

**Table 3.** Results with regard to a business ecosystem’s supplier dimension

		today		medium term	
		mean	median	mean	median
consultations by suppliers	adopters	2.10	2	2.82	3
	non-adopters	1.68	1	2.01	2
information exchange	adopters	2.33	2	3.21	3
	non-adopters	1.76	1	2.18	2
integration into suppliers’ production processes	adopters	1.99	2	2.82	3
	non-adopters	1.66	1	1.94	2
joint development activities	adopters	2.16	2	2.91	3
	non-adopters	1.75	1	2.07	2

To test proposition 3 and 4, the respondents were asked if IIoT adoption would result in the utilization of knowledge and resources of companies external to the own industry, the offering of joint, complementary product portfolios with competitors, extensive information exchanges with research institutions, and comprehensive, joint development activities with research institutions. A Mann-Whitney test resulted in significant differences between adopters and non-adopters regarding all items except for joint portfolio with competitors. This indicates that manufacturers only minimally operate as joint suppliers of a broader solution package together with direct competitors, as in both cases, the majority of respondents state a rather low manifestation. As Table 4 shows, adopters have a medium manifestation of external knowledge utilization with reference to today, i.e. a mean value of 2.85 and a median of 3, while non-adopters rated it rather low. This partly supports proposition 3.

With reference to research institutions, a similar picture emerges. While adopters show a manifestation of both items of at least 2.16 in average for today’s evaluation, non-adopters reach 1.85 at most. Taking a look at the medians reveals that more than half of non-adopters do not draw on knowledge of research facilities or conduct joint developments activities. In contrast, the median of adopters’ responses is 2, thus, proposition 4 is supported.

**Table 4.** Results with regard to a business ecosystem in terms of organizations external to a company’s own industry

		today		medium term	
		mean	median	mean	median
utilization of knowledge of companies external to industry	adopters	2.85	3	3.38	3
	non-adopters	2.03	2	2.49	3
information exchange with research institutions	adopters	2.41	2	2.97	3
	non-adopters	1.85	1	2.22	2
joint development activities with research institutions	adopters	2.16	2	2.82	3
	non-adopters	1.76	1	2.19	2

When it comes to the future assessment of the ecosystem configuration, i.e., proposition 5, both adopters and non-adopters expect an increasing development with regard to all requested items. Furthermore, it is conspicuous that the difference between today’s and future assessment is higher for adopters in all cases. Thus, proposition 5 is supported. Taking a closer look at the customer dimension shows that future information exchange with customers has the highest mean value for both adopters and non-adopters. A difference can be observed regarding the absolute increase of mean values. Non-adopters expect the highest rise for both information exchange and customer consultations. By way of contrast, adopters expect the highest increase in terms of customer integration into the own production processes, i.e., the item that necessitates the most intense customer integration and collaboration.

The ecosystems’ supplier perspective shows a quite similar picture. Among both adopters and non-adopters, future information exchange with suppliers experiences the highest estimation in terms of mean values. In contrast to the customer dimension, it is the same item experiencing the highest growth for both adopters and non-adopters, i.e.,

information exchange with suppliers. Nevertheless, for IIoT adopters, information exchange is closely followed by integration into suppliers' production processes, which again required the most intense collaboration with suppliers.

With respect to ecosystem participants, in addition to traditional value chain partners, our findings reveal an interesting aspect with reference to research institutions. Here, adopters indicate the highest future assessment for information exchange. Non-adopters, on the contrary, expect the highest manifestation for joint development activities with research institutions. Thus, it is the non-adopters, which expect the highest future manifestation for the item that requires the most intense collaboration.

## 6. DISCUSSION AND CONCLUSIONS

This study enhances existing IIoT research from a business perspective in several ways. Our findings show that the IIoT has an effect on manufacturers' business ecosystems. The empirical results reveal that in particular, relationships to traditional value chain members, i.e., customers and suppliers, are concerned since all examined aspects of these ecosystem dimensions show significant intensifications when comparing IIoT adopters and non-adopters, albeit at a rather low level. Furthermore, IIoT adoption is associated with increasing cooperation with research institutions in terms of utilization of external knowledge, as well as joint developments. This might be ascribable to the high novelty of the IIoT, its technological fundamentals, and its potential. Hence, manufacturers implementing the internet into their production environment have a high demand for knowledge, which is not available internally (yet). Interestingly, our findings show no significant difference between IIoT adopters and non-adopters with reference to cooperation with competitors. This shortage of extensive utilization of IIoT's potential associated with a joint, complementary product and service portfolio (Weill & Woerner, 2015) might arise from the companies' early state regarding adopting and applying the IIoT. To date, they concentrate on themselves and traditional value chain partners, while the required trust in direct competitors still has to be built. With reference to temporal development, this study shows a clear expectation of intensified of ecosystem integration in all dimensions, independently from the adoption state. Also, we learn that companies that have already adopted the IIoT or intend to do so in the medium term expect higher increases in all ecosystem aspects than do non-adopters.

The findings also provide valuable insights for practitioners since we present insights from manufacturers of different industries who already had advanced experience with the implementation of the IIoT. This serves as a source of learning for companies that are on the cusp of integrating the IIoT into their value creation activities. The IIoT-inherent digital connection of entire value chains necessitates a rethinking with reference to a company's relationships to customers as well as suppliers. Manufacturers should establish an open mindset toward both upstream and downstream value-added steps and establish a common willingness to proceed with the next wave of digital transformation of manufacturing. Moreover, we recommend that manufacturers increasingly cooperate with external research institutions, e.g., universities to benefit from a larger knowledge base, which enables them to quickly and establish targeted and required know-how. Although past behavior in competition has been characterized primarily by rival thinking, manufacturers are well-advised to increasingly cooperate with competitors with regard to a joint product and service offering. This does not necessarily mean giving up distinguishing and unique features, but leaving room to facilitate the full exploitation of the IIoT's potential.

Although the paper at hand provides several contributions, it also faces some limitations. The sample consists only of German manufacturing companies. Since the IIoT is also relevant for companies originating in other industry sectors, e.g., service providers, and other countries, future studies should consider respective companies. Particularly with regard to foreign companies, examining potential cultural influences and backgrounds might reveal interesting findings with reference to a company's business ecosystem. Moreover, this study does not differentiate between small and large companies. It is reasonable that large companies operate in a more complex ecosystem with a multitude of participants. Further, smaller companies might go with the flow rather than proactively develop their ecosystems. Therefore, future research should, in particular, differentiate between company sizes. Regarding the ecosystem perspectives, we based our examination on the results of thoroughly



analyzed expert interviews. Nevertheless, this cannot represent a company's business ecosystem in its entirety. Hence, future studies should consider other ecosystem perspectives and items as well.

## REFERENCES

- Arnold, C., Kiel, D., & Voigt, K.-I. (2016). How the Industrial Internet of Things Changes Business Models in Different Manufacturing Industries. *International Journal of Innovation Management*, 20(8), 1640015-1-1640015-25.
- Atzori, L., Iera, A., & Morabito, G. (2010). The Internet of Things: A survey. *Computer Networks*, 54(15), 2787-2805.
- Bauer, W., Schlund, S., Marrenbach, D., & Ganschar, O. (2014). *Industrie 4.0 – Volkswirtschaftliches Potenzial für Deutschland*. BITKOM & Fraunhofer IAO: Berlin & Stuttgart.
- Berman, S., & Korsten, P. (2014). Leading in the connected era. *Strategy & Leadership*, 42(1), 37–46.
- Bonekamp, L., & Sure, M., (2015). Consequences of Industry 4.0 on Human Labour and Work Organisation. *Journal of Business and Media Psychology*, 6(1), 33-40.
- Brettel, M., Friederichsen, N., Keller, M., & Rosenberg, M. (2014). How Virtualization, Decentralization and Network Building Change the Manufacturing Landscape: An Industry 4.0 Perspective. *International Journal of Mechanical, Aerospace, Industrial and Mechatronics Engineering*, 8(1), 37-44.
- Breznitz, D. (2014). *Why Germany Dominates the U.S. in Innovation*. Available at <https://hbr.org/2014/05/why-germany-dominates-the-u-s-in-innovation>.
- Cooper, D. R., & Schindler, P. S. (1998). *Business Research Methods*. Burr Ridge, IL: Irwin/McGraw-Hill.
- Creswell, J. W. & Plano Clark, V. L. (2011). *Designing and Conducting Mixed Methods Research*. Los Angeles, CA: Sage.
- Dais, S. (2014). Industrie 4.0 – Anstoß, Vision, Vorgehen. In Bauernhansl, T., ten Hompel, M. & Vogel-Heuser, B. (Eds.), *Industrie 4.0 in Produktion, Automatisierung und Logistik – Anwendung, Technologien, Migration* (pp. 625-634). Wiesbaden: Springer.
- Eloranta, V., & Turunen, T. (2016). Platforms in service-driven manufacturing. Leveraging complexity by connecting, sharing, and integrating. *Industrial Marketing Management*, 55, 178–186.
- Engelken, M., Römer, B., Drescher, M., & Welp, I. (2016). Transforming the energy system: Why municipalities strive for energy self-sufficiency. *Energy Policy*, 89, 365-377.
- Federal Bureau of Statistics. (2016). *Statistisches Jahrbuch 2016*. Wiesbaden, Germany: Federal Bureau of Statistics.
- Fowler, F. J. (1993). *Survey Research Methods* (2nd. ed.). Thousand Oaks: Sage.
- Geisberger, E. & Broy, M. (2012). *agendaCPS (acatech STUDIE)*. Heidelberg: Springer.
- Frazzon, E. M., Hartmann, J., Makuschewitz, T., & Scholz-Reiter, B. (2013). Towards Socio-Cyber-Physical Systems in Production Networks, *Procedia CIRP*, 7, 49-54.
- Gioia, D. A., Corley, K. G., & Hamilton, A. L. (2013). Seeking Qualitative Rigor in Inductive Research: Notes on the Gioia Methodology. *Organizational Research Methods*, 16(1), 15-31.
- Graebner, M. E. & Eisenhardt, K. M. (2004). The seller's side of the story: acquisition as courtship and governance as syndicate in entrepreneurial firms. *Administrative Science Quarterly*, 49(3), 366–403.

- Iansiti, M. & Levien, R. (2004). *The Keystone Advantage: What the New Dynamics of Business Ecosystems Mean for Strategy, Innovation, and Sustainability*. Boston: Harvard Business Press.
- Johnson, R. B. & Onwuegbuzie, A. J. (2004). Mixed Methods Research: A Paradigm Whose Time Has Come. *Educational Researcher*, 33(7), 14-26.
- Kelley, D. J., Peters, L., & O'Connor, G. C. (2009). Intra-organizational networking for innovation-based corporate entrepreneurship. *Journal of Business Venturing*, 24(3), 221-235.
- Kiel, D., Arnold, C., Collisi, M., & Voigt, K.-I. (2016). The Impact of the Industrial Internet of Things on Established Business Models. In Proc. *Int. Conf. Association for Management of Technology IAMOT 2016* (673-695). Orlando, FL.
- Kurniawan, S. (2008). Older people and mobile phones: A multi-method investigation. *International Journal of Human-Computer Studies*, 66(12), 889-901.
- Mazhelis, O., Luoma, E., & Warma, H. (2012). Defining an internet-of-things ecosystem. In Andreev, S., Balandin, S., & Koucheryavy, Y. (Eds.), *Internet of Things, Smart Spaces, and Next Generation Networking* (pp. 1-14). Berlin, Heidelberg: Springer.
- Miles, M. B. & Huberman, M. A. (1994). *Qualitative Data Analysis*. Thousand Oaks: Sage.
- Moore, J. F. (1997). *The death of competition. Leadership and strategy in the age of business ecosystems*. New York, NY: HarperBusiness.
- Müller, J. W. (2000). Possible Advantages of a Robust Evaluation of Comparisons. *Journal of Research of the National Institute of Standards and Technology*, 105(4), 551-555.
- Nagar, B. & Raj, T. (2013). An analytical case study of an advanced manufacturing system for evaluating the impact of human enablers in its performance. *Journal of Advances in Management Research*, 10(1), 85-99.
- Obermaier, R. (2016). *Industrie 4.0 als unternehmerische Gestaltungsaufgabe. Betriebswirtschaftliche, technische und rechtliche Herausforderungen*. Wiesbaden: Springer Gabler.
- Peltoniemi, M. & Vuori, E. (2004). Business ecosystem as the new approach to complex adaptive business environments. *Proceedings of eBusiness research forum*, 18, 267-281.
- Ramsey, E., Ibbotson, P. & McCole, P. (2008). Factors that impact technology innovation adoption among Irish professional service sector. *International Journal of Innovation Management*, 12(4), 629-654.
- Venkatesh, V., Brown, S. A., & Bala, H. (2013). Bridging the qualitative-quantitative divide: guidelines for conducting mixed methods research in information systems. *MIS Quarterly*, 37, 21-54.
- Vowles N., Thirkell, P., & Sinha, A. (2011). Different determinants at different times: B2B adoption of a radical innovation. *Journal of Business Research*, 64(11), 1162-1168.
- Weill, P. & Woerner, S. L. (2015). Thriving in an Increasing Digital Ecosystem. *MIT Sloan Management Review*, 45(4), 27-34.

Acta Infologica, İstanbul Üniversitesi Enformatik Bölümü bünyesinde Haziran ve Aralık aylarında olmak üzere yılda iki kez, makalelerin tam metin olarak yayımlandığı akademik hakemli elektronik bir dergidir. Bilimsel içeriğin doğru ve uygun olarak yayımlanabilmesi için tüm çalışmalar konusunda uzman en az iki hakem tarafından değerlendirilmekte olup değerlendirme sürecinde kör hakemlik yöntemi uygulanmaktadır. Değerlendirme sonucunda yayımlanması uygun görülen makaleler yayın sıralamasına alınarak makale sahibine bildirilir. Derginin yayın dili Türkçe ve İngilizce'dir.

Derginin hedef kitlesi veri-enformasyon-bilgi kavramlarını, bilgi-iletişim teknolojileri ve uygulamalarını temel alarak öncelikle Enformatik olmak üzere bu konularda disiplinlerarası alanda da çalışma yapan bilim insanları, araştırmacılar, uzman kişi ve kuruluşlardır. Değerlendirilmek üzere gönderilen tüm çalışmalar bilimsel yayın yapma etiğine uygun olarak hazırlanmalı ve aynı anda başka bir dergi, kongre, konferans vb. yerde değerlendirme sürecinde olmamalıdır. Makale eğer lisansüstü tezlerden üretilmiş veya tezin bir bölümü ise bu durum makale yazarı tarafından makaleye dipnot olarak belirtilmelidir.

Dergiye gönderilen makaleler Editörler tarafından alana özgün katkısı, bilimsel yöntem, anlatım özellikleri ve yazım kuralları açısından incelenir ve benzerlik tarama programından geçirilir. Bu kural ve koşullarla bağdaşmayan yazılar yayınlanmaz.

Makalenin dergide yayınlanmasından sonra makalenin kullanılması, kopyalanması, yayınlanmasına dair tüm telif hakları ACIN'a aittir. Yayımlanmış çalışmaların yazarlarına telif ücreti ödenmez. ACIN ve yazar ismi kaynak gösterilmeden makalelerden alıntı yapılamaz. Derginin tüm hakları saklıdır. Derginin hiçbir bölümü Yayın Sahibi Temsilcisi'nin izni olmaksızın ticari veya başka amaçla elektronik veya mekanik formatta çoğaltılamaz. ACIN ücretsizdir ve Dergipark ([dergipark.gov.tr/acin](http://dergipark.gov.tr/acin)) üzerinden dergiye erişilebilmektedir. ACIN'de yayımlanan yayınlardaki bilimsel içerik ve ifadelerle ilişkin tüm sorumluluk yazarlara ait olup dergi yayın yönetimine, editörlere veya İstanbul Üniversitesi Enformatik Bölümü'ne ait değildir.