



BİLİŞİM TEKNOLOJİLERİ DEPARTMANINDA KULLANICILARIN TALEPLERİNE CEVAP VERME SÜRESİNİN MAKİNE ÖĞRENMESİ İLE TAHMİN EDİLMESİ

Kerim Kürşat ÇEVİK^{1*}, Mehmet KAYAKUŞ²

¹ Akdeniz Üniversitesi, Uygulamalı Bilimler Fakültesi, Yönetim Bilişim Sistemleri Bölümü, Antalya, Türkiye

² Akdeniz Üniversitesi, Sosyal ve Beşeri Bilimler Fakültesi, Yönetim Bilişim Sistemleri Bölümü, Antalya, Türkiye

Anahtar Kelimeler

*Makine Öğrenmesi,
DVM,
Sınıflandırma,
Talep Süresi,
BT.*

Öz

Günümüzde şirketlerin artan rekabet şartlarından dolayı bilişim teknolojilerine olan ihtiyaç her geçen gün artmaktadır. Bilişim teknolojilerinin (BT) sorunsuz, hızlı ve güvenilir çalışması yapılan yatırım kadar önemlidir. Şirketlerde bulunan bilişim teknoloji(BT) departmanları yapılacak yatırımların planlanmasından, mevcut sistemin sorunsuz çalışmasından ve oluşabilecek sorunlara hızlı çözümler üretilmesinden sorumludurlar. Şirket çalışanlarının BT departmanına sorunları iletilmesi, süreci takip etmesi ve raporlandırması amacıyla bilgi işlem takip programları kullanılmaktadır. Böylece sorunların ve çözüm sürecinin yönetimi, bilgilendirmesi ve raporlandırılması profesyonel ve kolay yapılabilir. Sorunların hızlı çözülmesi ve çözüm süresinin bilinmesi çalışanlarının zamanı iyi kullanmasını sağlayacak ve belirsiz bekleme süresinin yaratacağı olumsuz etkileri ortadan kaldıracaktır. Bu çalışmada bir şirketin kullanıcıdan gelen talepleri çözme süresi makine öğrenmesi yöntemiyle tahmin edilmiştir. Bunun için kullanıcılardan gelen 2320 talep; departman, destek türü, sorumlu ve kategori olarak kayıt altına alınmaktadır. Sonuçtaki destek süreleri için bir sınıf yapısı ile test edilmiştir. Harcanan süreler 0-10 dakikadan başlayıp 90 dakika ve daha fazlası şeklinde 10'ar dakika aralıklarla on adet sınıfa ayrılmıştır. Bu veri setleri üzerinde makine öğrenme yöntemleri kullanılmıştır. Gerçekleştirilen testler sonucunda en iyi sonuç Destek Vektör Makineleri (Support Vector Machine-SVM) metodu kullanılarak tasarlanan model ile, eğitim başarısı %99.82, test başarısı ise %93.11 olarak ölçülmüştür. Bu sistem sayesinde kullanıcının bekleme süresi ve sorunun ortalama çözüm süresi tahmin edilmektedir.

PREDICTION OF SOLUTION TIME OF USER REQUESTS DELIVERED TO THE INFORMATION TECHNOLOGIES DEPARTMENT VIA MACHINE LEARNING

Keywords

*Machine Learning,
SVM,
Classification,
Request Time,
IT.*

Abstract

Today, the need for information technologies is increasing day by day due to the increasing competitive conditions of companies. Companies that make timely and adequate investments take advantage of their competitors and take a step forward. Investments in information technologies (IT) are as important as the smooth, fast and reliable investment. Therefore, companies need professional teams to protect the performance of information systems and to find solutions to the problems they will encounter. The information technology (IT) departments in companies are responsible for planning investments, the smooth operation of the existing system and the rapid solutions to the problems that may occur. The company's employees communicate problems and follow the process; IT departments often use computing tracking programs to provide reports to administrators about the work done. Thus, management, information and reporting of problems and the solution process can be done more professionally and easily. Fast-solving problems and knowing the wait time will allow company employees to use and plan time better and avoid the negative effects of uncertain wait time. In this study, it was tried to estimate the time of a company to solve requests from the user by machine learning method. For this,

* İlgili yazar / Corresponding author: kcevik@akdeniz.edu.tr, +90-242-310-6963

2320 requests from users; the department is registered as support type, responsible and category. Tested with a class structure for resulting support times. The time spent was divided into ten classes starting from 0-10 minutes and 11 minutes apart in the form of 90 minutes or more. Machine learning methods were used on these data sets. With the model designed using the Support Vector Machine (SVM) method, the best result as a result of the tests performed, the education success was measured as 99.82% and the test success as 93.11%. This system developed estimates the user's wait time and the average resolution time (minutes) of the problem.

Alıntı / Cite

Çevik, K., K., Kayakuş, M., (2020). Bilişim Teknolojileri Departmanında Kullanıcıların Taleplerine Cevap Verme Süresinin Makine Öğrenmesi ile Tahmin Edilmesi, Mühendislik Bilimleri ve Tasarım Dergisi, 8(3), 728-739.

Yazar Kimliği / Author ID (ORCID Number)

K.K. Çevik, 0000-0002-2921-506X
M. Kayakuş, 0000-0003-0394-5862

Makale Süreci / Article Process

Başvuru Tarihi / Submission Date	17.04.2020
Revizyon Tarihi / Revision Date	06.07.2020
Kabul Tarihi / Accepted Date	14.07.2020
Yayın Tarihi / Published Date	24.09.2020

1. Giriş (Introduction)

Bilişim Teknolojileri (BT) bilgiyi yakalama, depolama, işleme, geri alma ve iletme becerisi olarak tanımlanmaktadır. Günümüzde BT'leri hem yetenek hem de uygun maliyet konusunda önemli ilerleme kat etmiştir. Bu nedenle, bilgi yönetimini kolaylaştırmak için birçok kurum özel olarak tasarlanmış Bilişim Sistemleri (BS) kullanılmaktadır (Wu ve Wang, 2006). Hastane (Özkaraca vd., 2018), tedarik zinciri (Şahin ve Supçiller, 2015), lojistik (Öztürk vd., 2016) ve ulaşım (Yaslı ve Güvenasan, 2019) sistemlerinde bilişim teknolojilerinin sağladığı imkan ve olanaklardan faydalanılmaktadır.

BT bir şirketin hayatta kalması için bir zorunluluk durumuna gelmiştir ve BT departmanının işlevi giderek önem kazanmaktadır (Lee, Chen, ve Chang, 2008). Şirketler, giderek artan bir şekilde, bir şirketin stratejik seçimlerini ve değer zinciri faaliyetlerini desteklemek ve şekillendirmek için bilgi sistemleri kullanmaya başlamıştır. BT'nin dağıtım yeteneklerinin, bir şirketi rekabette ne kadar avantajlı konuma getirdiğini ve rekabet için ne kadar önemli olduğunu ispat etmiştir (Tian vd., 2010). BT alanındaki gelişmeler, şirketlerin yüksek hızlı iletişim ve bağlantı kurmasına olanak sağladığı için tedarik zincirlerinin gelişmesini sağlamıştır (Bardhan vd., 2006).

Kurumsal yapıda BT departmanının örgüt içerisindeki rolü ve etkinliği her geçen gün önemli ölçüde artmaktadır. Bir zamanlar bilgi sistemlerinin geliştiricisi ve operatörü olan BT departmanı artık çok daha kapsamlı bir role sahip sahiptir. Kişisel bilgisayarların kullanılması, bilgi teknolojisi kullanıcılarının daha fazla ve daha sık BT departmanı ile etkileşime girmesine neden olmaktadır. Kullanıcılar, BT departmanının donanım ve yazılım seçimi, kurulum, sorun çözme, ağ bağlantıları, sistem geliştirme ve yazılım eğitimi gibi sayısız görev konusunda kendilerine yardımcı olmasını beklemektedir (Pitt vd., 1995).

Şirketler kullanıcıların taleplerine kısa sürede ve güvenilir cevaplar vermek, işleri takip etmek, çalışmalarını raporlandırmak ve kullanıcıyı hızlı bir şekilde bilgilendirmek, iş yükünü daha yönetilebilir hale getirmek ve verimliliği artırmak için "Bilgi İşlem Talep Takip Sistemi" geliştirmişlerdir. Böylece BT departmanının verimliliğini ve servis kalitesini artmıştır (Coşkun ve Baykal, 2010).

Kurumsal yapılarda bulunan BT, şirketin verimliliğini, performansını ve rekabet gücünü doğrudan etkilemektedir. BS yapılacak yatırımlar kadar sistemin başarıyla sürdürülmesinde hayati öneme sahiptir. Bu yüzden şirketler BT desteğini dışarıda almak yerine kendi BT departmanını oluşturmayı tercih etmektedir. Böylece karşılaşılabilecek sorunlara daha kısa sürede ve güvenilir çözümler üretilebileceklerdir.

Kullanıcılar karşılaştıkları problemleri BT departmanın bildirdiklerinde ortalama çözüm süresini ve süreci bilmek istemektedirler. Böylece zamanlarını planlama ve daha verimli kullanma yeteneğine sahip olabileceklerdir.

Bu çalışmada kurumsal bir şirkette bulunan bilişim sisteminin, kullanıcıdan gelen problemlere çözüm üretme süresinin tahmini (sınıflandırması) makine öğrenmesi yöntemleri ile yapılmıştır. Bu çalışma sayesinde kullanıcılar karşılaştıkları sorunu bildirdikleri BT departmanından ortalama çözüm süresini öğrenebileceklerdir.

2. Kaynak Araştırması (Literature Survey)

Literatürde bilişim teknolojileri departmanlarının kullanıcı taleplerine cevap süresinin tahminini yapan çalışma bulunmamaktadır. Literatürde benzer çalışmalar başka bir alan olan çağrı merkezlerinin çözüm süresinin tahmini üzerine bulunmaktadır ve bu tahmin metotlarının başarısı üzerine yapılan çalışmalar oldukça sınırlıdır.

Kullanıcıların karşılaştıkları sorunları iletme ve çözüm bulma ihtiyacı birçok farklı kurumda önem arz etmektedir. Özellikle kurumlarda çağrı merkezi olarak adlandırılan birimlerde müşterilerin ihtiyaçlarına göre farklı bekleme süreleri bulunmaktadır. Burada sorunun önemi, departmanın yoğunluğu ve çalışan sayısı gibi değişkenler çözüm sürecini etkilemektedir. Çağrı merkezinde kullanıcıların bekleme süresinin azaltılması ve bekleme süresinin tahmini için farklı uygulamalar ve teknikler geliştirilmiştir.

Yapılan bir çalışmada, çağrı merkezini arayan kullanıcıların bekleme süresini azaltmak için akıllı dış arama sistemini önermiştir. Burada teknolojik alt yapı kullanarak çağrı merkezine gelecek aramalar önceden belirlenmiş ve akıllı dış arama sistemiyle aramalar otomatik olarak yapılmıştır. Böylece çağrı Merkezinin yoğunluğu önemli ölçüde azaltılmıştır (Sayın, 2013).

Bankalarda müşterilerin çağrı merkezlerinde bekleme sürelerini optimize etmek için kuyruk teorisinden faydalanılmaktadır. Çağrı merkezlerinin hızı ve kalitesi müşteri memnuniyetini oluşturan etkenlerin başında gelmektedir. Bu yüzden yöneticiler kuyrukta bekleme süresini azaltmak ve hizmet kalitesini arttırmak istemektedirler. Çağrı merkezine gelen aramaların sayısı ve süresi tahmin edilemediği için bankaların bu sistemlere yaptıkları yatırımlar için net bir model önerilememektedir. Çalışan sayısının arttırılması bekleme süresini azaltacaktır ama günün her saati yoğun olmayan çağrı Merkezinin maliyetini arttıracaktır. Ayrıca müşteri temsilcilerinin atıl zamanları oluşacaktır. Bu sorunlara çözüm olarak bekleme sürelerinin tahmini ve modellenmesi için dinamik kuyruk modelleri kullanılması önerilmektedir. Böylece yoğun günler için part-time müşteri temsilcilerinin değerlendirilmesi sağlanabilecektir (Kazan vd., 2012).

Telekomünikasyon sektöründe kullanılan çağrı merkezleri müşteri ile doğrudan iletişim kurmak ve müşteri memnuniyetini arttırmak için önem teşkil etmektedir. Bu çalışmada çağrı Merkezinin iyileştirmesi için müşteri gözünden bakılarak ve kısıtlar teorisi kullanılarak çözüm önerisinden bulunulmuştur. Burada ilk olarak müşteriden gelen sorunlar gerçeklik ağacı ile tespit edilmiş ve üç temel başlık altında sınıflandırılmıştır. Daha sonra geçiş ağaçları kullanılarak tespit edilen problemler için çözüm uygulamaları belirlenmiştir. Problemlerin çözümleri sonrasında oluşacak durumlar gelecek gerçeklik ağacı ile ortaya koyulmuştur. Böylece bir telekomünikasyon şirketi için problemlerin temel nedenleri tespit edilerek bir yol haritası çıkarılması sağlanmıştır (Birgün vd., 2011).

Çağrı merkezlerinde çalışan müşteri temsilcisi sayısı ile arayan müşteri sayısı arasında optimum bir bağıntı kurulması önemlidir. Burada önerilen modelde çağrı merkezini arayan müşterilerin bazı temel sorunları kendi kendine çözmesi hedeflenmiştir. Kullanıcının arama nedeni tespit edilmiş ve sorunu kendi başına çözümü için bir yol haritası sunulmuştur. Geliştirilen örnek olayda sim kart blokesinin çözümü test edilmiştir. Çalışma sonucunda çağrı merkezlerine müşteri gelişlerinin %5 azaldığı belirlenmiştir. Ayrıca müşterilerin sistemde bekleme sürelerinin 6,48 saniye; kuyrukta bekleme sürelerinin 6,84 saniye azaldığı görülmüştür (Keksın vd., 2018).

Yapılan çalışmalar çağrı merkezini arayan kişilerin belirsiz bekleme sürelerinden şikâyet ettiğini göstermiştir. Belirsiz bekleme süreleri daha uzun hissedilmekte ve müşterilerde kızgınlık hissi yarattığını tespit edilmiştir (Çiçek ve Atılgan, 2012; Maister, 1985). Başka bir çalışmada ise kullanıcılara ortalama bekleme süresinin haber verildiğinde beklemenin daha kısa algılandığı sonucu ortaya çıkmıştır (Ahmadi, 1984). Bekleme süresini bilen müşterilerin/kullanıcıların stresi azaldığı ve süreyi daha az algıladığı belirlenmiştir (Osuna, 1985). Çağrı merkezlerinde müşterilere ne kadar bekleyeceklerinin süresinin verilmesi şirketin hizmet kalitesini arttıracaktır. Böylece müşterilerinin memnuniyeti artacak ve güven duygusu pekişecektir (Çiçek ve Atılgan, 2012).

Thiongane ve arkadaşları basit sezgisel tarama temelli iki yeni gecikme öngörücüsü geliştirerek çağrı merkezleri için gecikme süresi tahmini gerçekleştirmiştir. İlk tahmin modelinde hala kuyrukta bekleyen müşteri bilgileri kullanılmıştır. Nihai bekleme süreleri, kuyruktaki ilerlemelerinin basit bir tahminini kullanarak tahmin edilmiştir. İkinci modelde ise geçmiş veriler kullanılmıştır. Her kuyruk boyutu için, koşullu bir bekleme süresi, geldiklerinde önlerinde aynı kuyruk uzunluğunu bulan müşterilerin geçmiş gecikmelerinden tahmin edilmiştir (Thiongane ve Chan, 2016).


Literatürde bu konuda yapılmış çalışma araştırması yapıldığında; tam anlamıyla çalışmamızda yapmaya çalıştığımız cevap verme süresini tahmin etmeye yönelik bir akademik çalışmaya rastlanamamıştır. Bu sebeple hem akademik hem de gerçek hayatta çalışmanın etkinliği ve özgünlüğü oldukça açıktır.

3. Materyal ve Yöntem (Material and Method)

3.1. Kurumlarda Bilgi İşlem Merkezleri (Information Processing Centers in Institutions)

Günümüzde birçok kamusal ve özel kuruluşlar kendi bilgi işlem merkezlerine sahiptirler. Bu sayede şirket içinde meydana gelebilecek teknoloji temelli sorunlara doğru, güvenilir ve kısa sürede çözüm üretebilirler.

BT departmanı kendisine gelen sorunları departman, destek türü ve problemin kategorisine göre sınıflandırmaktadır. Bu bilgiler ışığında çözüm talep edilen problem sorunun çözümüne en uygun kişiye aktarılmakta ve problemin çözüm süreci başlamaktadır. Şekil 1. de çözüm aşaması görülmektedir.



Şekil 1. Problem Çözüm Şeması (Problem Solution Chart)

Çalışmada bir kurumsal şirkette bulunan 16 departmandan gelen talepler incelenmiştir. Bu talepler özelliklerine göre 3 destek türüne ve 6 kategoriye ayrılmıştır. Tablo 1.de talepleri görülmektedir.

Tablo 1. Problemin Sınıflandırılması (Problem Classification)

DEPARTMAN	DESTEK TÜRÜ	KATEGORİ	SORUMLU
Yönetim	Destek	Bilgi Güvenliği Yönetim Sistemi (BGYS)	A
Bilgi işlem	Evrak	Kurumsal kaynak planlaması (ERP)	B
İnsan kaynakları	Proje	Donanım (Pc, Laptop, yazıcı vb.)	C
İdari işler		Sunucu ile ilgili işlemler	D
Laboratuvar		Yazılım (Windows, office)	E
İhracat		Diğer işlemler	F
Proje ekibi			
ARGE			
Operasyon			
Finans			
Dış işlemler			
Kalite			
Muhasebe			
Satış			
Ticaret			
Üretim			

Bu çalışmada bilişim alanında faaliyet gösteren bir firmanın BT departmana gelen 2320 çağrının incelenmesi yapılmıştır. Tablo 1'de görüldüğü gibi dört farklı sütun içerisinde alınan giriş verileri (Departman, Destek türü, Kategori, Sorumlu) ile Harcanan Süre çıkış verileri makine öğrenmesi yöntemlerinden SVM ile sınıflandırılmıştır. Harcanan sürenin elde edilen verilerde 1 dakika ile 1000 dakika arasında değiştiği gözlemlenmiştir. Verilerin incelenmesi sonucunda 90 dakika sonrasındaki verinin çok fazla olmadığı da görülmüştür. Bu sebeple sınıflandırma probleminin çıkış sınıfları (Harcanan Süre) oluşturulurken 10'ar dakikalık aralıklar belirlenmiş ve 90 dakika sonrası süreler aynı sınıfa dahil edilmiştir. Sonuçta 0-10 dakikadan başlayıp 90 dakika ve sonrası şeklinde biten 10 adet Harcanan Süre sınıfı oluşturulmuştur. Oluşturulan veri setinin örnek bir kısmı Tablo 2'de verilmiştir.

Tablo 2. Çalışmada Kullanılan Veri Seti (Data Set Used in the Study)

DEPARTMAN	DESTEK TÜRÜ	KATEGORİ	SORUMLU	HAR. SÜRE
Bilgi İşlem	Destek	PC, Laptop, Ekran, Yazıcı...vb	A	30
Satış	Destek	Windows, Office, Java, Adobe...vb	B	10
Muhasebe	Destek	ERP, Dynamics Axapta	C	20
Operasyon	Proje	Kurumsal kaynak planlaması (ERP)	D	40
Finans	Destek	Windows, Office, Java, Adobe...vb	E	60
Operasyon	Proje	Sunucu ile ilgili işlemler	F	90
Satın alma	Destek	Windows, Office, Java, Adobe...vb	A	10
Ticaret	Evrak	ERP, Dynamics Axapta	B	30

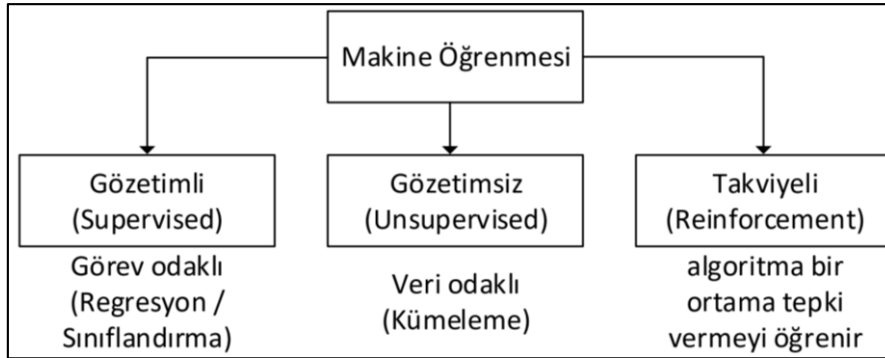
Tablo2. Devamı (Continued)

DEPARTMAN	DESTEK TÜRÜ	KATEGORİ	SORUMLU	HAR. SÜRE
İdari İşler	Destek	Windows, Office, Java, Adobe...vb	C	10
İnsan Kaynakları	Destek	PC, Laptop, Ekran, Yazıcı...vb	D	30
Satın alma	Destek	Bilgi Güvenliği Yönetim Sistemi (BGYS)	E	70
Bilgi İşlem	Proje	PC, Laptop, Ekran, Yazıcı...vb	F	50
...

3.2. Makine Öğrenmesi (Machine Learning)

Makine öğrenmesi bilgisayar programlarının kendisine öğretilen tecrübeler yoluyla gelecek durumları tahmin etmesini sağlamayı amaçlamaktadır. Makine öğrenmesinin temel dayanağı, giriş verisini alabilen algoritmalar oluşturmak ve çıktılarını yeni veriler ortaya çıktıkça güncellerken bir çıktıyı tahmin etmek için istatistiksel analiz kullanmaktır. Makine öğrenmesinde, veriler eğitim ve test veri seti olmak üzere iki bölümden oluşmaktadır. Programlar eğitim veri seti ile öğrenme sağlayarak, test verilerini tahmin etmeye çalışmaktadırlar. Bu tahminlerden daha iyi sonuç elde etmek için eğitim veri setinin geniş tutulması önerilmektedir. Çünkü makineler ne kadar çok veriyi öğrenirse, o kadar tecrübe edinecek ve iyi sonuçlar üretebileceklerdir (Karakoyun ve Hacıbeyoğlu, 2014).

Literatürde birçok makine öğrenmesi yöntemi geliştirilmiş olup bunlardan bazıları; k-en yakın komşu algoritması, basit (naive) Bayes sınıflandırıcı, karar ağaçları, lojistik regresyon analizi, k-ortalamlar algoritması, rastgele orman algoritması, destek vektör makinaları ve yapay sinir ağları vb. yöntemlerdir. Bu yaklaşımların bir kısmı tahmin ve kestirim, bir kısmı kümeleme ve bir kısmı da sınıflandırma yapabilme yeteneğine sahiptir (Atalay ve Çelik, 2017).

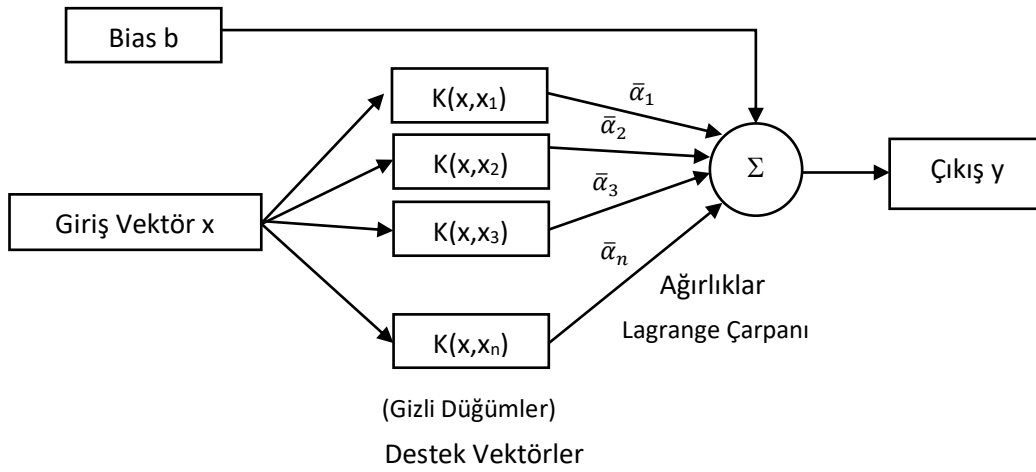


Şekil 2. Makine Öğrenmesi Çeşitleri (Types of Machine Learning) (Candan, Emir, Doğan, ve Kumbasar, 2018)

Makine öğrenmesinde öğrenme stratejileri; gözetimli, gözetimsiz ve pekiştirmeli (takviyeli) olmak üzere üç grupta incelenebilir (Şekil 2). Gözetimli öğrenmede girdi kümesinin yanında çıktı kümesi de verilirken, gözetimsiz öğrenmede bilgisayarın bu çıktı kümesi verilmeden öğrenmesi beklenir. Sınıflandırma ve regresyon problemleri gözetimli öğrenmeye, kümeleme ve yoğunluk kestirimi ise gözetimsiz öğrenmeye örnek verilebilir (Kalaycı, 2018). Makine öğrenmesinin bir çeşidi olan takviyeli öğrenme (Reinforcement Learning), bulunduğu ortamı algılayan ve ortamında hareket yapan özerk bir ajanın, hedefine ulaşabilmesinde doğru kararlar almayı nasıl öğrenebileceğini gösterir. Ajan, ortamda bir hareket yaptığı zaman, yeni durumun optimal olması için bir ödül veya ceza değeri ile takviye edilir. Ajan, amacına ulaşmak için gerçekleştirebileceği en iyi eylemi seçmeye çalışır. Ajanın amacı, en büyük toplam ödülü üreten hareketlerin sırasını öğrenmektir (Candan vd., 2018).

3.3. Destek Vektör Makinaları Sınıflandırıcısı (Support Vector Machine Classifier)

Support Vector Machine (SVM) sınıflandırma, örüntü tanıma ve regresyon problemlerinin çözümü için temelleri istatistiksel öğrenme teorisine (Vapnik-Chervonenkis (VC) teorisi) dayanarak Vapnik tarafından geliştirilmiş bir yöntemdir (Cortes ve Vapnik, 1995). SVM algoritması muhtemelen en yaygın kullanılan çekirdek öğrenme algoritmasıdır. Optimizasyon teorisinde iyi yapılandırılmış kavramları kullanarak sağlam örüntü tanıma performansı sağlar (Bottou ve Lin, 2007). Genel SVM yapısı Şekil 3'de gösterilmiştir.




Şekil 3. SVM Genel Yapısı (SVM General Structure) (Deka, 2014)

Şekil 3’de gösterildiği gibi $K(x, x_n)$ değerleri çekirdek fonksiyonunu, $\bar{\alpha}_n$ değerleri Lagrange Çarpanlarını göstermektedirler. Giriş değerleri çekirdek fonksiyonu ile çarpılarak iç çarpımlar oluşturulur, Lagrange Çarpanları ise ağırlıkları oluşturmaktadır. SVM’de bir örneğe ilişkin çıktı değeri, girdilerin iç çarpımları ile Lagrange çarpanlarının bağımsız kombinasyonlarının toplamına eşittir (Ayhan ve Erdoğan, 2014). SVM, kullanılan verilerin ayırt edilme durumuna göre Doğrusal ve Doğrusal Olmayan SVM’ler olarak ikiye ayrılabilir.

3.3.1. Doğrusal SVM (Linear SVM)

Doğrusal SVM sadece ayırt edilebilir doğrusal verilere uygulanabilen en basit SVM modelidir. Eğitim veri kümesi $D = \{(\vec{x}_i, y_i), i = 1 \dots N\}$ olduğu ve N adet elemandan oluştuğu düşünülürse. $y_i \in \{-1, +1\}$, sınıf etiketi $\vec{x}_i \in R^n$ ve n boyutlu uzayda herhangi bir örnektir. $f(\vec{x}) = \vec{w}^T \vec{x} + b$ ifadesindeki \vec{w}^T karar fonksiyonun normalini, \vec{x} ifadesi bu doğru üzerinde bulunan noktaları, b ise eğilim değerini göstermektedir. Amaç \vec{w}^T ve b’yi eğitim verileri yardımıyla bulmaktır, sonuç olarak sistemi eğitmektir. Tüm destek vektör makinelerinde amaç Şekil 4’de olduğu gibi verileri iki sınıfa ayırmaktır. Şekil 4’de kesikli çizgiler ile ifade edilen doğrular üzerindeki vektörler destek vektör olarak isimlendirilir ve yumuşak ayırım çizgisi bu vektörler üzerinden geçer. İki yumuşak ayırım çizgisinin ortasındaki doğru ise sert ayırımdır ve $f(\vec{x}) = \vec{w}^T \vec{x} + b = 0$ fonksiyonuyla çizilir (Küçüksille ve Ateş, 2013).



Şekil 4. Doğrusal Sınıflara Ayırma (Classification into Linear Classes) (Küçüksille ve Ateş, 2013)

Şekil 4’de görüleceği üzere $f(\vec{x}) = \vec{w}^T \vec{x} + b \geq 1$ durumu ($y_i = 1$) birinci sınıfı ve $f(\vec{x}) = \vec{w}^T \vec{x} + b \leq -1$ durumu ise ikinci sınıfı ($y_i = -1$) temsil eder (Kaynar vd., 2016).

İki sınır arasındaki uzaklık $\lambda = 2/\|\vec{w}\|^2$ formülü ile ifade edilir. Hedef, λ değerini maksimum yapmak olduğundan dolayı $1/\lambda$ ifadesinin minimum olması gerekmektedir. Buna bağlı sınırlama ise $y_i (w^T x_i + b) - 1 \geq 0, y_i \in \{-1, +1\}$ ’dir. Optimizasyon problemi, verilen bazı kısıtlamalar altında bir fonksiyonun maksimumunu ya da minimumunu bulmaktır. Eşitlik 1’de verilmiş olan ilgili problemin duali, Lagrange denklemleri, Eşitlik 2 ve Eşitlik 3’de verilen “Karush-Kuhn-Tucker (KKT)” in kısıtları yardımıyla çözülür (Kaynar vd., 2016; Küçüksille ve Ateş, 2013).


$$L(b, w, a) = \frac{1}{2} w^T w - \sum_{i=1}^N \alpha_i [y_i (w^T x_i + w_0) - 1], \alpha_i \geq 0, \forall_i \quad (1)$$

$$\frac{\partial L}{\partial w_j} = 0, \forall_j \quad (2)$$

$$\frac{\partial L}{\partial w_n} = 0 \quad (3)$$

3.3.2. Doğrusal Olmayan SVM (Nonlinear SVM)

Doğrusal olarak ayırt edilebilen veri kümelerini ayırabilen fonksiyonlar pratik uygulamalar için oldukça kısıtlıdır. Çünkü pratik uygulamaların çoğunda doğrusal SVM kullanılarak sonuç alınmaz. Bu gibi durumlarda SVM çeşitli dönüşüm işlemleri vasıtasıyla girdi uzayı daha yüksek düzeyli bir uzaya taşıyarak, doğrusal ayırma işlemi gerçekleştirmeye çalışır (Çomak, 2008). Şekil 5'te giriş uzayının özellik uzayına çevrilmesi gösterilmektedir.



Şekil 5. Özellik Uzayında Doğrusal Ayırma (Linear Separation in Property Space) (Deka, 2014)

Girdi uzayının daha yüksek boyutlu uzaya taşınması için genel tanımı $\phi(x)^T \phi(x_i) = K(x_i, x_j)$ olan bir çekirdek fonksiyonu kullanılır. Çekirdek fonksiyonları, SVM algoritmasında önemli bir yere sahiptir. Doğru çekirdek fonksiyonunun seçimi sınıflandırma başarımını doğrudan etkilemektedir. Bu çekirdek fonksiyonlar *Mercer Teoremi* olarak bilinen matematiksel kurama uygun olmalıdır. Bu kural yüksek boyutta çalışılırken çekirdek fonksiyonların her zaman iki girdi vektörünün iç çarpımı şeklinde ifade edilmesini sağlamaktadır. SVM'de literatürde sıklıkla kullanılan çekirdek fonksiyonlarından bazıları Eşitlik 4 de verilmiştir (Köse vd., 2015).

$$K(x_i, x_j) = \begin{cases} \text{Doğrusal: } x_i^T x_j \\ \text{Polinom: } (x_i^T x_j + 1)^d \\ \text{Gauss (RBF): } \exp(-\gamma \|x_i - x_j\|^2) \\ \text{Sigomoid: } \tanh(\gamma x_i x_j + C) \end{cases} \quad (4)$$

3.4. Yapay Sinir Ağları (Artificial Neural Networks)

Yapay sinir ağları (YSA), beynin görevini yerine getirme şeklini örnek olarak modelleyen bir yapay zekâ yöntemidir. Birbiri ile etkilemiş de ve paralel olarak bağlı nöronlardan oluşan bir yapıdır (Akgöz vd., 2010).

YSA mimarisi giriş, gizli ve çıkış katmanı olmak üzere üç katmandan oluşmaktadır. Giriş katmanı dış ortamdan verileri almak için kullanılmakta; çıkış katmanı ise hedef katmanı temsil etmektedir (Saplıoğlu ve Çimen, 2010). Gizli katman, giriş ile çıkış katmanı arasında bulunmaktadır. Gizli katmadaki katman sayısı ve her katmandaki nöron sayısı problemin karmaşıklığına göre değişmektedir.

YSA yönteminde öğrenmenin amacı giriş katmanı ile çıkış katmanı arasındaki en uygun ilişkinin bulunmasını amaçlanmaktadır. Bunun için de nöronlar arasındaki bağlantı ağırlıklarının iyi ayarlanması gerekmektedir (Saplıoğlu ve Çimen, 2010). Başarıyı arttırmak için ileri ve geri yayılım olmak üzere iki şekilde hesaplama yöntemi kullanılmaktadır. İleri yayılımda, giriş değerleri ağırlık katsayıları ile çarpılarak gizli katmana oradan da çıkış katmanına ilerlemektedir. Geri yayılımda ise istenen değer ile elde edilen değer arasındaki farka göre ağırlık katsayıları geriye doğru yayılım yapmaktadır.

3.5. Basit Bayes Yöntemi (Naive Bayes Method)

Bayes Yöntemi 1980'li yıllarda ortaya çıkan ve olasılık kuramını temel alan bir yapay zekâ tekniğidir (Sorias, 2015). Bayes teoreminde değişkenler arasındaki ilişkiler şartlı olasılıklar ortaya koyulmaktadır. Model sonucu

olasılık olarak sunulmaktadır (Nikovski, 2000). Bayes teoremi özellikle eldeki verilerin yetersiz olduğu belirsiz durumlarda çok işe yaramaktadır (Charniak, 1991). Bayes Teoremi:

$$P[A_n | B] = \frac{P[B | A_n] \cdot P[A_n]}{\sum P[B | A_i] \cdot P[A_i]} \quad (5)$$

Burada B bilgi sahibi olunan olayı, A(n) farklı koşullu olayları temsil etmektedir. $P[A | B]$, B olduğunda A'nın olasılığını ifade etmektedir. Başka bir ifade ile B olayı gerçekleştiğinde A olayının oluşma olasılığıdır.

3.6. Lojistik Regresyon (Logistic Regression)

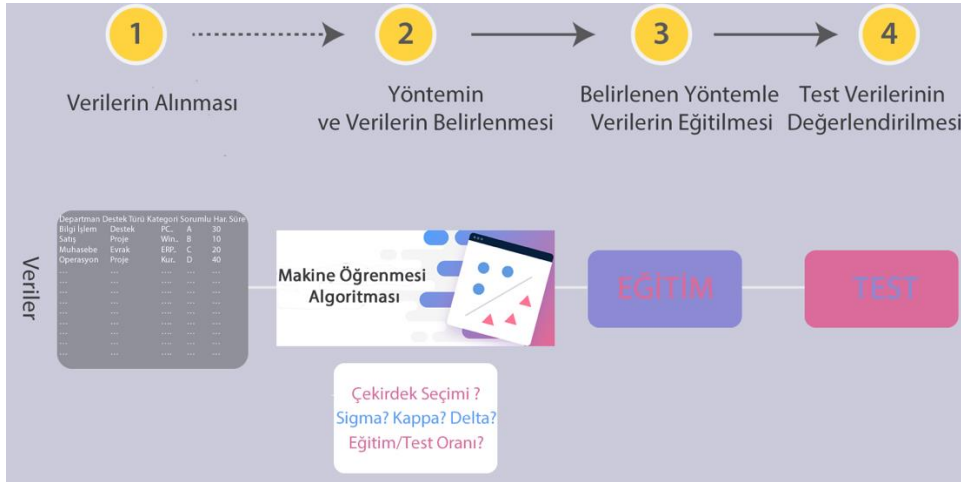
Lojistik regresyonun amacı bağımlı ve bağımsız değişkenler arasında ilişkiyi tanımlayabilecek bir model kurmaktır (Çokluk, 2010). Lojistik regresyon analizinde, bağımlı değişkenin sonucu en az iki olasılıklı olan değişken olarak kullanılması gerekmektedir (Aziz ve Osman, 2005). Bağımlı değişkenin alabileceği değerlerin 0-1 arasında olmasını sağlamak için bağımsız değişkenler ve bağımlı değişken arasında eğrisel bir ilişki aşağıdaki denklemden gibi ifade edilir (Budak ve Erpolat, 2012):

$$E(y_i) = \rho_i = \frac{1}{1 + \exp(-y_i)} \quad (6)$$

Bu denklem doğrusal olmadığı için β parametrelerini tahmin etmek zor olduğundan denklem doğrusallaştırılarak Logit modeli elde edilir.

$$L_i = \ln\left(\frac{\rho_i}{1-\rho_i}\right) = \beta_0 + \beta_1\chi_1 + \beta_2\chi_2 + \dots + \beta_k k \quad (7)$$

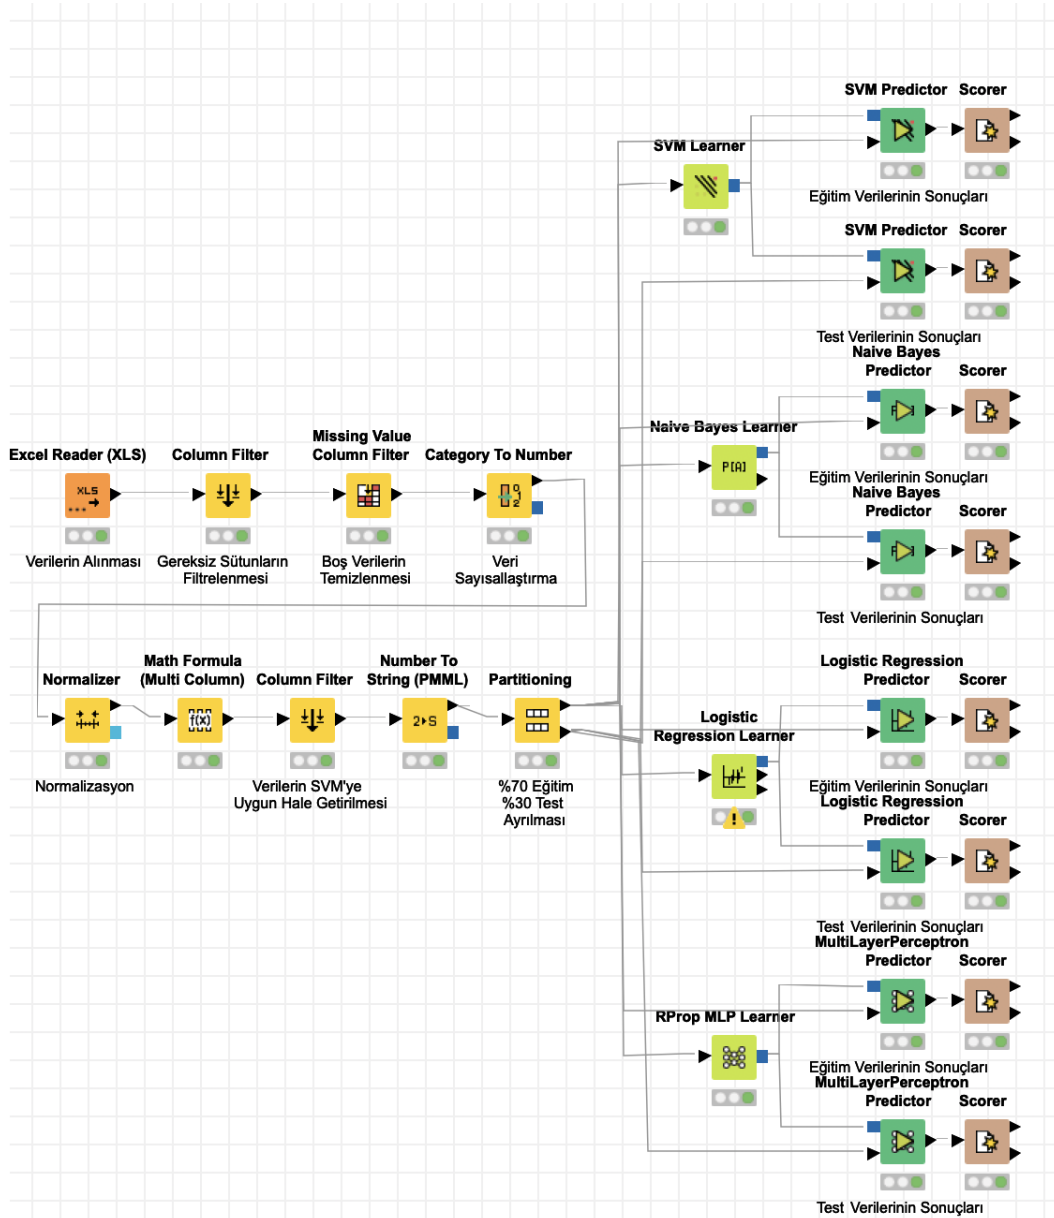
4. Deneysel Sonuçlar (Experimental Results)



Şekil 6. Gerçekleştirilen Sistemin Akış Şeması (Flow Chart of the Implemented System)

Gerçekleştirilen çalışmada bir firmanın BT destek departmanına gelen yardım taleplerinin ortalama ne kadar sürede çözüme ulaştırılabileceği konusu ele alınmıştır. Bunun için firmanın belirli bir aralıkta kendisine gelen sorunların özellikleri ve bu sorunların çözüm süreleri alınmıştır. Gerçekleştirilen sistemin akış şeması Şekil 6'da gösterilmiştir.

Öncelikle veriler çalışmanın ikinci bölümünde anlatıldığı şekilde düzenlenmiştir. Düzenlenen verilerin sisteme alınması ile toplamda 2320 adet kayıt çalışmada kullanılmıştır. **Departman, Destek Türü, Kategori ve Sorumlu** alanları Makine Öğrenmesi Algoritmasının giriş vektörlerini, **Harcanan Süre** ise çıkış vektörünü oluşturmaktadır. 2320 adet verinin %70'i olan 1624 adet kayıt eğitim için, geriye kalan %30'u yani 696 adet kayıt test için kullanılmıştır. Eğitim ve Test verilerinin seçimi tamamen rastgele ve sınıflara göre dengeli olarak yapılmıştır. Makine öğrenmesi uygulaması için günümüzde sıklıkla veri biliminde başvurulan Knime paket programı kullanılmıştır. KNIME sistemi, yeni araç entegrasyonlarla kolayca genişletilebilen, güçlü bir veri sistemine sahip açık kaynaklı bir yazılımdır (Fillbrunn vd, 2017). KNIME programını kullanarak kullanıcılar verileri işleyebilir ve program içindeki düğümlerden oluşan iş akışlarını modelleyebilir. Knime güçlü ve sezgisel bir kullanıcı arayüzüne sahiptir; yeni modüllerin veya düğümlerin entegrasyonunu kolaydır (Berthold vd., 2009). KNIME görüntü işleme, yapay zekâ veya veri analizi gibi çeşitli araştırma alanlarında yaygın olarak kullanılmaktadır (Dietz ve Berthold, 2016; Yu vd., 2016). Gerçekleştirilen sistemin tasarımı ve parametreleri Şekil 7'de gösterilmiştir.



Şekil 7. Gerçekleştirilen Çalışmanın Knime Uygulaması (Knime Application of the Work Performed)

Gerçekleştirilen Makine Öğrenmesi tabanlı sınıflandırma probleminde sonuçların performansını ölçmek için literatürde sıklıkla kullanılan metriklerden yararlanılmıştır. Bu metrikler sınıflandırma sonucunda ortaya çıkan karşıtlık matrisi (confusion matrix-CM) kullanılarak ortaya çıkartılır. CM tahmin edilen değerler ile gerçek değerler arasındaki benzerlik sayılarının bir tabloda gösterilmesidir. Tabloda bulunan bu değerler True Positives (TP), True Negatives (TN), False Positives (FP) ve False Negatives (FN)'dir. Tablo 1’de standart bir CM gösterilmiştir (Chen vd., 2020).

Tablo 3. Karşıtlık Matrisi (Confusion Matrix) (Çelik ve Aslan, 2019)

		GERÇEK DEĞERLER		TOPLAM (%)
		0	1	
TAHMİN EDİLEN	0	TP	FP	Precision
	1	FN	TN	Negative Predictive Value
TOTAL		Recall, Sensitivity	Specificity	Accuracy

Yapılan testler sonucunda en başarılı sonucu verdiği için gerçekleştirilen çalışmada SVM yönteminde çekirdek fonksiyonu olarak Gauss (RBF), Bayes yönteminden Default Probability değeri 0.0001, Lojistik Regresyon yönteminde Solver Stochastic Average Gradient ve Yapay Sinir Ağlarında 1 gizli katmanda 10 nöron kullanılmıştır.

Çalışmada kullanılan veri seti materyal bölümünde belirtilen makine öğrenmesi yöntemleri ile test edilmiştir. Test

verisi sonuçlarına göre basit (naive) Bayes sınıflandırma başarımı %88.50, lojistik regresyon analizi sınıflandırma başarımı %89.94, yapay sinir ağları sınıflandırma başarımı %91.37 ve Destek Vektör Makineleri (SVM) sınıflandırma başarımı %93.11 olarak alınmıştır. Elde edilen sonuçlara göre en yüksek test başarısına sahip yöntem Çalışmanın bu aşamasından sonra uygulanan makine öğrenmesi yöntemlerinden en fazla doğruluk oranına sahip olan SVM yöntemi detaylı olarak açıklanmıştır.

Gerçekleştirilen SVM uygulamasında BT departmanına gelen taleplerin ortalama kaç dakikada çözüme ulaşacağı ile ilgili sınıflandırma sonuçları için oluşturulan eğitim verisi Karşıtlık Matrisi Tablo 2 'de verilmiştir. Tabloya göre 1624 kaydın 1621 adedini doğru sınıflandırmış, 3 adedini ise yanlış sınıflandırmıştır. Dolayısıyla eğitim aşaması başarı oranı %99.82'dir.

Tablo 4. SVM Eğitim İşlemi Sonrası Oluşan Karşıtlık Matrisi (Confusion Matrix After SVM Training Process)

GERÇEK TAHMİN (DAKİKA)	0-10	10-20	20-30	30-40	40-50	50-60	60-70	70-80	80-90	90+	BAŞARI (%)
0-10	436	0	0	0	0	0	0	0	0	0	100
10-20	0	482	0	0	0	0	0	0	0	0	100
20-30	0	1	166	0	0	0	0	0	0	0	99,4
30-40	0	0	0	171	0	0	0	0	0	0	100
40-50	0	0	0	0	56	0	0	0	0	0	100
50-60	0	0	0	0	0	24	0	0	0	0	100
60-70	0	0	0	0	0	0	98	0	0	0	100
70-80	0	0	0	0	0	0	2	8	0	0	80
80-90	0	0	0	0	0	0	0	0	4	0	100
90+	0	0	0	0	0	0	0	0	0	176	100
TOPLAM BAŞARI ORANI											99,82

Eğitimi tamamlanan SVM modelinin testi için daha önce sisteme gösterilmemiş 696 kayıt test için kullanılmıştır. Test sınıflarından 648 adedi doğru sınıflandırılmış, 48 adedi yanlış sınıflandırılmıştır. Dolayısıyla test başarı oranı %93.11 olarak bulunmuştur. Sınıf bazlı başarı oranları ile birlikte tüm bu değerler Tablo 3'de gösterilmiştir. Tabloda kırmızı renkte gösterilen alanlar hatalı sınıflandırmayı belirtmektedir.

Tablo 5. SVM Test İşlemi Sonrası Oluşan Karşıtlık Matrisi (Confusion Matrix After SVM Testing)

GERÇEK TAHMİN (DAKİKA)	0-10	10-20	20-30	30-40	40-50	50-60	60-70	70-80	80-90	90+	BAŞARI (%)
0-10	185	5	0	0	0	0	0	0	0	0	97
10-20	4	202	0	0	0	0	0	0	0	0	98
20-30	0	10	65	2	0	0	0	0	0	0	97
30-40	0	0	2	60	4	0	0	0	0	2	88
40-50	0	0	0	7	8	0	0	0	0	0	53
50-60	0	0	0	0	3	2	0	0	0	1	33
60-70	0	0	0	0	0	0	33	1	0	5	85
70-80	0	0	0	0	0	0	2	2	0	0	50
80-90	0	0	0	0	0	0	0	0	4	1	80
90+	0	0	0	0	0	0	0	0	0	86	100
TOPLAM BAŞARI ORANI											93,11

Eğitim ve test işlemleri sonucunda oluşan zıtlık matrisleri incelendiğinde eğitime giren sınıflardaki verilerin durumunun test sınıflandırma başarısının doğru orantılı olduğu gözlemlenmiştir. Örneğin eğitimde 70-80 dakika aralığında çözülen problem sayısı (10) ve eğitim başarısı(%80) ile test başarısı (%50) tutarlıdır. Dolayısıyla eğitimdeki kayıt sayısı az olan sınıfların kayıtlarına ekleme yapılırsa, sistemin sınıf bazlı başarısı da artacaktır. Bu sebeple gerçekleştirilen sistem %93.11 genel başarı oranı ile bilişim teknolojileri departmanında kullanıcıların taleplerine cevap verme süresini sınıflandırmada oldukça başarılıdır.

5. Sonuç ve Tartışma (Result and Discussion)

Kurumsal şirketlerde bulunan bilişim teknolojileri departmanının temel görevlerinden bir tanesi de şirket çalışanlarının karşılaştıkları teknolojik sorunlara çözümler üretmektir. Belirsiz ve çözüm süresi kestirilemeyen sorunlar iş gücü kaybına neden olacaktır. Ayrıca çalışanlar üzerinde stres yaratmakta ve departmana duyulan güven duygusu zarar görmektedir. Bütün bu sebeplerden ve şirketin hizmet kalitesini arttırmak için kullanıcılara karşılaştıkları sorunlar için ortalama bir bekleme ve çözüm süresi önerilmesi önemlidir.

Bu çalışmada bir şirketteki bilişim teknolojilerine gelen sorunların çözüm süresi tahmin edilmeye çalışılmıştır. Bunun için şirketlerde kullanıcıların sorunlarını bildirmeleri, süreci takip etmeleri ve raporlandırmaları için kullanılan bilgi işlem takip sisteminden elde edilen veriler kullanılmıştır. Kullanıcılardan gelen 2320 talep; departman, destek türü, sorumlu ve kategori olarak kayıt altına alınmıştır.

Makine öğrenme yöntemlerinden Destek Vektör Makineleri (Support Vector Machine -SVM) metodu kullanılarak sorunun çözüm süresi sınıfı en yüksek oranda tahmin edilmiştir. Veri seti eğitim (% 70) ve test (%30) olarak iki ayrılmıştır. Tasarlanan model de eğitim başarısı %99.82, test başarısı ise %93.11 olarak ölçülmüştür. Diğer makine

öğrenmesi yöntemlerinde ise başarı oranları Bayes için %89.14, lojistik regresyon için %89.92, yapay sinir ağları için ise %92.09'dir. Bunun sebebi kategorik verilerde SVM yönteminin daha başarılı sonuçlar çıkartması olarak görülebilir.

Geliştirilen bu sistem sayesinde kullanıcılar BT departmanına sorunları bildirdiklerinde çözüm sürecini öğrenebileceklerdir. Böylece şirketin hizmet kalitesi ve BT departmanına duyulan güven hissi artacaktır.

Çıkar Çatışması (Conflict of Interest)

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir. No conflict of interest was declared by the authors.

Kaynaklar (References)

- Ahmadi, K., S., 1984. Effects of social influences and waiting on time judgment. *Perceptual and motor skills*, 59(3), 771-776.
- Akgöz, B., Baltacıoğlu, A., Civalek, Ö., ve Korkmaz, K., 2010. Deprem Hasarlarının Hızlı Tespitinde Yapay Sinir Ağları Yaklaşımı. *Mühendislik Bilimleri ve Tasarım Dergisi*, 1(1), 22-27.
- Atalay, M., Çelik, E., 2017. Büyük Veri Analizinde Yapay Zekâ Ve Makine Öğrenmesi Uygulamaları-Artificial Intelligence and Machine Learning Applications in Big Data Analysis. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(22), 155-172.
- Ayhan, S., Erdoğan, Ş., 2014. Destek Vektör Makineleriyle Sınıflandırma Problemlerinin Çözümü İçin Çekirdek Fonksiyonu Seçimi. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 9(1), 175-201.
- Aziz, A., ve Osman, Ç., 2005. İstatistiksel Analiz Teknikleri "SPSS'te İşletme Yönetimi Uygulamaları". Emek Ofset, İkinci Baskı, Ankara.
- Bardhan, I., Whitaker, J., Mithas, S., 2006. Information Technology, Production Process Outsourcing, and Manufacturing Plant Performance. *Journal of Management Information Systems*, 23(2), 13-40.
- Berthold, M., R., Cebren, N., Dill, F., Gabriel, T., R., Kötter, T., Meinel, T., ve Wiswedel, B., 2009. KNIME-the Konstanz Information Miner: Version 2.0 And Beyond. *AcM SIGKDD explorations Newsletter*, 11(1), 26-31.
- Birgün, S., Öztepe, T., Şimsit, Z., T., 2011. Bir Çağrı Merkezinde Müşteri Şikayetlerinin Düşünce Süreçleri İle Değerlendirilmesi. Paper presented at the XI. Üretim Araştırmalar Sempozyumu.
- Bottou, L., Lin, C., J., 2007. Support Vector Machine Solvers. *Large scale kernel machines*, 3(1), 301-320.
- Budak, H., ve Erpolat, S., 2012. Kredi Riski Tahmininde Yapay Sinir Ağları ve Lojistik Regresyon Analizi Karşılaştırılması. *AJIT- e: Online Academic Journal of Information Technology*, 3(9), 23-30.
- Candan, F., Emir, S., Doğan, M., Kumbasar, T., 2018. Takviyeli Q-Öğrenme Yöntemiyle Labirent Problemi Çözümü Labyrinth Problem Solution with Reinforcement Q-Learning Method. Paper presented at the TOK2018 Otomatik Kontrol Ulusal Toplantısı, Kayseri.
- Charniak, E., 1991. Bayesian networks without tears. *AI magazine*, 12(4), 50-50.
- Chen, W., Li, Y., Xue, W., Shahabi, H., Li, S., Hong, H., Pradhan, B., 2020. Modeling Flood Susceptibility Using Data-Driven Approaches Of Naïve Bayes Tree, Alternating Decision Tree, And Random Forest Methods. *Science of The Total Environment*, 701, 134979.
- Cortes, C., Vapnik, V., 1995. Support-vector Networks. *Machine learning*, 20(3), 273-297.
- Coşkun, C., Baykal, A., 2010. Dicle Üniversitesi Bilgi İşlem Online Talep Takip Sistemi. *Akademik Bilişim*.
- Çelik, Ö., Aslan, A., F., 2019. Gender Prediction from Social Media Comments with Artificial Intelligence. *Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 23(6), 1256-1264.
- Çiçek, E., Atılgan, K., Ö., 2012. Hizmet İşletmelerinde Çağrı Merkezi ve Bekleme Hattı Uygulamalarına Tüketici Odaklı Bir Yaklaşım. *Sosyal Ekonomik Araştırmalar Dergisi*, 12(23), 81-102.
- Çokluk, Ö., 2010. Lojistik regresyon analizi: Kavram ve uygulama. *Kuram ve Uygulamada Eğitim Bilimleri*, 10(3), 1357-1407.
- Çomak, E., 2008. Destek Vektör Makinelerinin Etkin Eğitimi İçin Yeni Yaklaşımlar. *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*.
- Deka, P., C., 2014. Support Vector Machine Applications in The Field Of Hydrology: A Review. *Applied soft computing*, 19, 372-386.
- Dietz, C., ve Berthold, M., R., 2016. KNIME For Open-Source Bioimage Analysis: A Tutorial. In *Focus on Bio-Image Informatics* (pp. 179-197). Springer, Cham.
- Fillbrunn, A., Dietz, C., Pfeuffer, J., Rahn, R., Landrum, G. A., ve Berthold, M., R., 2017. KNIME For Reproducible Cross-Domain Analysis Of Life Science Data. *Journal Of Biotechnology*, 261, 149-156.
- Kalaycı, T. E., 2018. Kimlik Hırsızlığı Web Sitelerinin Sınıflandırılması İçin Makine Öğrenmesi Yöntemlerinin Karşılaştırılması. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 24(5), 870-878.
- Karakoyun, M., Hacıbeyoğlu, M., 2014. Biyomedikal Veri Kümeleri İle Makine Öğrenmesi Sınıflandırma Algoritmalarının İstatistiksel Olarak Karşılaştırılması. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 16(48), 30-42.
- Kaynar, O., Görmez, Y., Yıldız, M., Albayrak, A., 2016. Makine öğrenmesi yöntemleri ile Duygu Analizi. Paper presented at the International Artificial Intelligence and Data Processing Symposium (IDAP'16).
- Kazan, H., Ergülen, A., Çoruhlu, N., 2012. Banka Çağrı Merkezlerinde Bekleme ve Müşteri İlişkiler Yönetimi: Bir Kamu Bankası Uygulaması. *Afyon Kocatepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(1), 251-268.
- Keskin, G. A., Çolak, M., Kostak, G., K., 2018. Bir Çağrı Merkezindeki Bekleme Sürelerinin Kuyruk Modelleri İle İyileştirilmesi. *Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 20(1), 55-68.

- Köse, U., Güraksın, G. E., Deperlioğlu, Ö., 2015. Diabetes Determination Via Vortex Optimization Algorithm Based Support Vector Machines. Paper presented at the 2015 Medical Technologies National Conference (TIPTEKNO).
- Küçükşille, E. U., Ateş, N., 2013. Destek Vektör Makineleri ile Yaramaz Elektronik Postaların Filtrelenmesi. Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi, 6(1).
- Lee, A. H., Chen, W.-C., Chang, C., J., 2008. A Fuzzy AHP and BSC Approach for Evaluating Performance of IT Department in The Manufacturing Industry in Taiwan. Expert Systems with Applications, 34(1), 96-107.
- Maister, D., H., 1985. The Psychology of Waiting Lines. Retrieved from <http://www.busi.mun.ca/jbarnes/b9015/Maister-WaitingLines.pdf>
- Nikovski, D., 2000. Constructing Bayesian networks for medical diagnosis from incomplete and partially correct statistics. IEEE Transactions on Knowledge and Data Engineering, 12(4), 509-516.
- Osuna, E., E., 1985. The Psychological Cost of Waiting. Journal of Mathematical Psychology, 29(1), 82-105.
- Özkaraca, O., Acar, E., Peker, M., Türk, E., 2018. A Fuzzy Logic Based Clinical Decision Support System For Emergency Services. Mühendislik Bilimleri ve Tasarım Dergisi, 6(3), 375-382.
- Öztürk, Z., K., Güngör, K., ve Lepki, B., 2016. Lojistik Sektöründe Çok Amaçlı Kapı Atama Problemleri İçin Bir Karar Destek Sistemi. Mühendislik Bilimleri ve Tasarım Dergisi, 4(1), 21-29.
- Pitt, L. F., Watson, R. T., Kavan, C., B., 1995. Service Quality: A Measure of Information Systems Effectiveness. MIS quarterly, 173-187.
- Saphioğlu, K., ve Çimen, M., 2010. Yapay Sinir Ağlarını Kullanarak Günlük Yağış Miktarının Tahmini. Mühendislik Bilimleri ve Tasarım Dergisi, 1(1), 14-21.
- Sayın, M., 2013. Çağrı Merkezi Gelen Çağrılarındaki Bekleme Süresinin Azaltılması: Akıllı Dış Arama Uygulaması. Akademik Bilişim Konferansı, Antalya.
- Sorias, S., 2015. Psikiyatrik Tanıda Betimsel ve Kategorik Yaklaşımların Kısıtlılıklarını Aşmak: Bayes Ağlarına Dayalı Bir Öneri. Türk Psikiyatri Dergisi, 26(1), 1-12.
- Şahin, Y. ve Supçiller, A., 2015. Tedarikçi Seçimi İçin Bir Karar Destek Sistemi. Mühendislik Bilimleri ve Tasarım Dergisi, 3(2), 91-104.
- Thiongane, M., Chan, W., ve l'Ecuyer, P., 2016. New history-based delay predictors for service systems. Winter Simulation Conference (WSC16), pp. 425-436.
- Tian, J., Wang, K., Chen, Y., Johansson, B., 2010. From IT Deployment Capabilities to Competitive Advantage: An Exploratory Study in China. Information Systems Frontiers, 12(3), 239-255.
- Yaslı, F., ve Güvensan, M., A., 2019. Ulaşım Türü Tanımadaki Enerji Kısıtlı Cihazlar İçin Ayırt Edici Özellikler. Mühendislik Bilimleri ve Tasarım Dergisi, 7(1), 90-102.
- Yu, S., Zhao, D., Chen, W., ve Hou, H., 2016. Oil-Immersed Power Transformer Internal Fault Diagnosis Research Based On Probabilistic Neural Network. Procedia Computer Science, 83, 1327-1331.
- Wu, J.-H., ve Wang, Y., M., 2006. Measuring KMS success: A respecification of the DeLone and McLean's model. Information ve Management, 43(6), 728-73