

T.C.
DOKUZ EYLÜL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
YÖNETİM BİLİŞİM SİSTEMLERİ ANABİLİM DALI
YÖNETİM BİLİŞİM SİSTEMLERİ PROGRAMI
YÜKSEK LİSANS TEZİ

GENİŞ ALAN AĞLARINDA AĞ PERFORMANSININ
RAPORLANMASINI SAĞLAYAN ÖRNEK BİR
UYGULAMA

Ahmet CANSEVER

Danışman

Doç. Dr. Can AYDIN

İZMİR - 2020

TEZ ONAY SAYFASI



YEMİN METNİ

Yüksek Lisans Tezi olarak sunduğum “Geniş Alan Ağlarında Ağ Performansının Raporlanmasını Sağlayan Örnek Bir Uygulama” adlı çalışmanın, tarafımdan, akademik kurallara ve etik değerlere uygun olarak yazıldığını ve yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve bunu onurumla doğrularım.

....../....../2020

Ahmet CANSEVER

ÖZET
Yüksek Lisans Tezi
Geniş Alan Ağlarında Ağ Performansının
Raporlanmasını Sağlayan Örnek Bir Uygulama
Ahmet CANSEVER

Dokuz Eylül Üniversitesi
Sosyal Bilimler Enstitüsü
Yönetim Bilişim Sistemleri Anabilim Dalı
Yönetim Bilişim Sistemleri Programı

Bu çalışmanın amacı, geniş alan ağlarında ağ trafiğini izleyerek geçmiş bant genişliği kullanımlarının iş analitiği kapsamında değerlendirilmesiyle geçmişte meydana gelen olayları/dalgalanmaları ve nedenlerini bulmaya çalışmaktır. Bunun yanında, geçmiş kullanımlara makine öğrenmesi tekniklerini uygulayarak zaman serisi analizi ile geleceğe yönelik tahmin yaparak kurum gereksinimleri hakkında bilgi edinilmesini sağlamaktır. Çalışma kapsamında geliştirilen uygulama, ağ trafiğini izleyerek kullanılan bant genişliği değerlerini ve değer aşımalarını kayıt altında tutmaktadır. Aynı zamanda, performansla ilgili oluşabilecek sorunların kaynak sebeplerinin de teşhis edebilmesi amaçlanmıştır. Tahminleme için elde edilen veri seti üzerinde Prophet, LSTM ve ARMA algoritmaları uygulanmış ve model performans değerleri en uygun olan algoritma kullanılmıştır. Uygulamanın web ara yüzlü ve kullanıcı dostu olarak tasarlanması öngörülmüştür. Raporlama bölümü için PHP, tahminleme bölümü için ise Python dilinin kullanılması kararlaştırılmış ve veri tabanı olarak da MySQL kullanılmıştır.

Anahtar Kelimeler: Geniş Alan Ağları, Bant Genişliği, Network, Makine Öğrenmesi, İş Analitiği.

ABSTRACT
Master's Thesis
Reporting Network Performance in Wide Area Networks
An Example Application
Ahmet CANSEVER

Dokuz Eylül University
Graduate School of Social Sciences
Department of Management Information Systems
Management Information Systems Program

The purpose of this study is to try to find past events / fluctuations and their causes by evaluating past bandwidth usage within the scope of business analytics by monitoring network traffic in wide area networks. In addition, by applying machine learning techniques to past uses, it is to provide information about institution requirements by making predictions about the future through time series analysis. The application developed within the scope of the study records the bandwidth values and overruns used by monitoring network traffic. At the same time, it is aimed to diagnose the causes of performance problems. Prophet, LSTM and ARMA algorithms were applied on the dataset obtained for estimation and the algorithm with the most suitable model performance values was used. It is foreseen to design the application as web interface and user friendly. It was decided to use PHP for the reporting section and Python for the prediction section and MySQL was used as the database.

Keywords: Wide Area Networks, Bandwidth, Network, Machine Learning, Bussiness Analytics.

**GENİŞ ALAN AĞLARINDA AĞ PERFORMANSININ RAPORLANMASINI
SAĞLAYAN ÖRNEK BİR UYGULAMA**

İÇİNDEKİLER

TEZ ONAY SAYFASI	ii
YEMİN METNİ	iii
ÖZET	iv
ABSTRACT	v
İÇİNDEKİLER	vi
KISALTMALAR	ix
TABLolar LİSTESİ	x
ŞEKİLLER LİSTESİ	xi
GİRİŞ	1

BİRİNCİ BÖLÜM

BANT GENİŞLİĞİNİN BİLGİ SİSTEM AĞLARINDAKİ ÖNEMİ

1.1. PROBLEMİN TANIMI	3
1.2. ARAŞTIRMANIN KISITLARI	4
1.3. İLGİLİ ÇALIŞMALAR	4

İKİNCİ BÖLÜM

BİLGİSAYAR AĞLARI

2.1. BİLGİSAYAR AĞLARI VE ÇEŞİTLERİ	6
2.1.1. Yerel Alan Ağları	6
2.1.2. Metropolitan (Kentsel) Alan Ağları	6
2.1.3. Geniş Alan Ağları	7
2.2. AĞ TOPOLOJİLERİ VE ÇEŞİTLERİ	8
2.2.1. Fiziksel Topoloji	8
2.2.2. Mantıksal Topoloji	9

2.2.3. Bus Topoloji	9
2.2.4. Star Topoloji	9
2.2.5. Ring Topoloji	10
2.2.6. Mesh Topoloji	10
2.3. AĞ BAĞLANTI CİHAZLARI	10
2.3.1. Ağ Kartı	10
2.3.2. Repeater (Tekrarlayıcı)	11
2.3.3. Hub	11
2.3.4. Bridge (Köprü)	11
2.3.5. Switch	12
2.3.6. Router	12
2.3.7. Firewall (Güvenlik Duvarı)	12

ÜÇÜNCÜ BÖLÜM

RAPORLAMA İLE İLGİLİ KAVRAMLAR

3.1. İŞ ANALİTİĞİ	13
3.1.1. İş Analitiğinin Artan Önemi	13
3.1.2. İş Analitiğinin Türleri	15
3.1.2.1. Tanımlayıcı Analitik	15
3.1.2.2. Teşhis Edici Analitik	15
3.1.2.3. Öngörücü Analitik	16
3.1.2.4. Yönlendirici Analitik	16
3.2. İŞ ZEKÂSI	17
3.2.1. İş Zekâsı Kavramı	17
3.2.2. İş Zekâsı Mimari Yapısı	20
3.3. MAKİNE ÖĞRENMESİ	21
3.4. ZAMAN SERİLERİ	25
3.4.1. Zaman Serisi Kavramı	25
3.4.2. Zaman Serilerinde Performans Değerlendirme Yöntemleri	25
3.4.2.1. Ortalama Hata Karesi (MSE)	25
3.4.2.2. Ortalama Karesel Hatanın Karekökü (RMSE)	26
3.4.2.3. Ortalama Mutlak Hata (MAE)	26

3.4.3. Zaman Serilerinde Kullanılan Algoritmalar	27
3.4.3.1. Uzun Kısa Süreli Bellek (LSTM)	27
3.4.3.2. Otoresif Bütünleşik Hareketli Ortalama Modeli (ARIMA)	28
3.4.3.3. Facebook Prophet	29

DÖRDÜNCÜ BÖLÜM

AĞ PERFORMANS RAPORLAMA SİSTEMİNİN TASARIMI VE UYGULAMASI

4.1. UYGULAMA İLE İLGİLİ TANIMLAR	30
4.1.1. Bant Genişliği	30
4.1.2. SNMP (Simple Network Management Protocol)	30
4.1.3. MRTG (Multi Router Traffic Grapher)	31
4.1.4. RRDTool	31
4.1.5. Flask	31
4.2. METODOLOJİ	31
4.3. SİSTEM TASARIMI	33
4.3.1. Yöntem	33
4.3.2. Uygulama Arayüz Tasarımı	34
4.4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA	45
4.4.1. Raporlama	45
4.4.2. Tahminleme	48
SONUÇ	58
KAYNAKÇA	60

KISALTMALAR

S.	Sayfa Numarası
YBS	Yönetim Bilişim Sistemleri
SNMP	Simple Network Management Protocol
MRTG	Multi Router Traffic Grapher
LAN	Local Area Network
MAN	Metropolitan Area Network
WAN	Wide Area Network
LSTM	Long Short Term Memory
ACF	Autocorrelation Function
PACF	Partial Autocorrelation Function
BPS	Bits Per Second

TABLÖLER LİSTESİ

Tablo 1: İş Zekâsının Faydaları	s. 19
Tablo 2: Prophet Modeli Metrik Hesaplamaları	s. 48
Tablo 3: Prophet Modeli Tahmin Değerleri	s. 49
Tablo 4: LSTM Modeli Metrik Hesaplamaları	s. 51
Tablo 5: LSTM Modeli Tahmin Değerleri	s. 51
Tablo 6: ARMA Modeli Metrik Hesaplamaları	s. 54
Tablo 7: ARMA Modeli Tahmin Değerleri	s. 55
Tablo 8: ARMA, LSTM ve Prophet Modelleri Performans Karşılaştırması	s. 56



ŞEKİLLER LİSTESİ

Şekil 1: İş Zekâsı Mimarisi	s. 20
Şekil 2: Makine Öğrenmesinin Temel Uygulama Modeli	s. 22
Şekil 3: Makine Öğrenmesi Yöntemleri	s. 23
Şekil 4: 4 Katmanlı LSTM Bloğu	s. 28
Şekil 5: Sistem Geliştirme Yaşam Döngüsü	s. 32
Şekil 6: Uygulama Çalışma Prensibi	s. 33
Şekil 7: Uygulama Giriş Paneli	s. 34
Şekil 8: Uygulama Genel Görünümü	s. 35
Şekil 9: Cihaz Oluşturma Paneli	s. 36
Şekil 10: Cihaz Listeleme Paneli	s. 36
Şekil 11: Grafik Oluşturma Paneli	s. 37
Şekil 12: Grafik İzleme Paneli	s. 38
Şekil 13: Grafik Ortalamaları	s. 39
Şekil 14: Grafiğe Alarm Eşik Değerlerinin Eklenmesi	s. 40
Şekil 15: Grafiğe Eklenen Alarm Ayarlarının Yapılması	s. 41
Şekil 16: Alarm Değerleri Eklenmiş Grafik Görünümü	s. 41
Şekil 17: Alarm Konsol Ekranı	s. 42
Şekil 18: Alarm Logları	s. 42
Şekil 19: Cihaz Durumları	s. 43
Şekil 20: Tahmin Sayfası Veri Giriş Ekranı	s. 43
Şekil 21: Örnek Kod Parçacığı	s. 44
Şekil 22: Tahmin Sonucu	s. 44
Şekil 23: 6 Aylık Bant Genişliği Kullanımı	s. 45
Şekil 24: Ocak Ayı Bant Genişliği Kullanımı	s. 45
Şekil 25: Şubat-Mart-Nisan Ayları Bant Genişliği Kullanımı	s. 46
Şekil 26: Mayıs-Haziran Ayları Bant Genişliği Kullanımı	s. 46
Şekil 27: 2 Günlük Gece Bant Genişliği Kullanım Durumu	s. 47
Şekil 28: 6 Aylık Kurum Dışına Giden Trafik Durumu	s. 47
Şekil 29: Prophet Modeli Tahmin Grafiği	s. 48
Şekil 30: LSTM Modeli Kod Parçacığı	s. 50

Şekil 31: LSTM Modeli Tahmin Grafiği	s. 50
Şekil 32: Durağanlık Test Sonuçları	s. 52
Şekil 33: ACF ve PACF Grafikleri	s. 52
Şekil 34: Auto ARIMA Sonucu	s. 53
Şekil 35: ARMA Modeli Göstergeleri	s. 53
Şekil 36: ARMA Modeli Tahmin Grafiği	s. 54
Şekil 37: Model Karşılaştırma Grafiği	s. 56
Şekil 38: 30 Günlük Tahmin Grafiği	s. 57



GİRİŞ

Teknoloji, hayatın daha verimli, daha kolay veya daha keyifli hale getirilmesi için malzeme, araç, teknik ve güç kaynaklarının kullanımını içerir. İletişim, ulaşım, öğrenme, üretim, işletmelerde verimlilik ve çok daha fazlası için teknoloji kullanılmalıdır. Günlük hayatta oldukça geniş bir yere sahip olan bilişim cihazlarının en önemli kullanım alanını iletişim oluşturmaktadır. Bilişim cihazlarının birbirleriyle iletişim kurabilmesi için aralarında bir bağlantı olması gerekir. Belirli kurallar dâhilinde birbirleriyle iletişim kurabilen cihazların oluşturduğu yapıya ağ adı verilir.

Dünyayı tamamen saran kablolar, okyanusların altından geçerek ülkeleri birbirlerine bağlamaktadırlar. Her ülkenin omurgasına bağlanan kablolar, radyo sinyalleri ve uydu bağlantıları ile verilerin iletimini sağlamaktadır. Bu da dünya üzerindeki en büyük Geniş Alan Ağını yani İnterneti oluşturmaktadır.

Ülkemizde ilk başlarda ağırlıklı olarak çevirmeli hatlarla internete bağlanmaya başlandı. Daha sonra yine telefon hatlarını kullanan ucuz bir teknoloji olan ve çok daha fazla bant genişliği sunan ADSL kullanıldı. ADSL'den sonra en büyük alternatif, geniş bant internet türü olan MetroEthernet yani fiber internet oldu. Fiber İnternet sayesinde çok yüksek bant genişliklerine ulaşıldı. Eskilerde 56K modemlerle internete bağlanılırken şuan 1000 Mbps hızlara ulaşabilmektedir.

Yüksek gerilim hattından elektriğin trafolara, oradan da kablolarla evlere iletilmesi gibi, veriler de bağlantı kapasitesinin yüksek olduğu veri merkezlerinden diğerlerine ve evlere kadar dağılmaktadır. Büyük kovadan küçük kaplara aktarılan su gibi bant genişliği de bizlere ulaştıkça daralmaktadır. Bu noktada bant genişliğinin takip edilmesi mecburiyeti doğmaktadır. Çünkü bant genişliği arttıkça maliyet de ona göre artmaktadır. 20 Mbps bant genişliği ile yapılacak işe 50 Mbps ayrılması gereksiz yere kaynak kullanımıdır. Tam tersi 50 Mbps bant genişliği ile yapılacak işe de 20 Mbps bant genişliği ayırmak dar boğaz oluşturmaktan başka bir şey değildir ve hizmetin aksamasına neden olacaktır. Günümüz teknolojisinde internet tabanlı uygulamaların sayısı hızla artmakta ve bunun sonucunda geniş alan ağlarının yetmemesine sebep olmaktadır. Ağlardaki bu durum verilerin akışı için ağ trafiğinde ciddi performans sorunlarına neden olmaktadır.

Çalışmanın amacı, işletmelerde ağ trafiğini izleyerek geçmiş bant genişliği kullanımlarının iş analitiği kapsamında değerlendirilmesiyle geçmişte olan olayları/dalgalanmaları ve nedenlerini bulmaya çalışmaktır. Bunun yanında, geçmiş kullanımlara makine öğrenmesi tekniklerini uygulayarak zaman serisi analizi ile geleceğe yönelik tahmin yaparak kurum gereksinimleri hakkında bilgi edinilmesi sağlamaktır.

Bu çalışma dört bölümden oluşmaktadır. Birinci bölümde, bant genişliğinin bilgi sistem ağlarındaki önemi ve literatürdeki çalışmalar hakkında bilgiler verilmiştir.

İkinci bölümünde, bilgisayar ağları ile ilgili tanımlar, ağ teknolojileri, ağ çeşitleri ve ağ bağlantı cihazları hakkında bilgiler verilmiştir.

Üçüncü bölümde, raporlamada kullanılan iş analitiği, iş zekâsı, makine öğrenmesi ve zaman serileri ayrıntılandırılmıştır.

Son bölümde, uygulama tasarlama aşamasında kullanılan kavramlar incelenmiş, bant genişliği, snmp, mrtg, rrdtool ve flask hakkında bilgilere yer verilmiştir. Devamında uygulama geliştirilmiş olup uygulamanın yöntemi ve tasarımı anlatılmıştır. Geliştirilen uygulamanın kullanımı ile ilgili detaylı bilgiler verilmiştir.

BİRİNCİ BÖLÜM

BANT GENİŞLİĞİNİN BİLGİ SİSTEM AĞLARINDAKİ ÖNEMİ

Bant genişliği, dijital iletişim ile ilgili bir terimdir. Bant genişliği veri aktarımının hızıyla eşanlamıdır. Belirli bir zaman diliminde iki veri noktası arasında taşınabilecek kesin veri miktarını ifade eder. Genel olarak, ağ bant genişliği metrik olarak saniye başına bit (bps) olarak ifade edilir. Bununla birlikte, modern ağlar şimdilerde saniyede megabit (Mbps) olarak da adlandırılan hızlarını saniyede milyon bit olarak ölçüyor. Benzer şekilde, saniyede gigabit (Gbps) olarak adlandırılan, saniyede milyarlarca bit de dijital ağın bir parçasıdır.

Bir ağın performansını etkileyen birden fazla etken bulunmaktadır. Veri kaybı, gecikme sorunları ve hız kesmeleri gibi faktörler ağı etkileyebilir ve bunun sonucunda sanki düşük bant genişliği sorunu varmış gibi görünebilir. Kullanılan tüm ağlar için gereken bant genişliği aynı olmayabilir. Bir VoIP görüşmesi için 56 Kbps, standart bir video için 1-2 Mbps ve HD bir video için ise 4-5 Mbps gerekebilir.

Bir web sayfasının tarayıcıya ne kadar hızlı yüklendiğini belirlemek için bant genişliği oldukça önemlidir. Örneğin, ağır grafik yüklü bir web sitesinin 10 Gbps veya daha yüksek bant genişliğine ihtiyacı olacaktır. Benzer şekilde, daha basit bir web sitesinin nispeten daha az bant genişliğine ihtiyacı olacaktır. Yüksek bant genişliği, web uygulamalarını ve videoları kusursuz bir şekilde kullanmaya izin verecektir.

1.1. PROBLEMİN TANIMI

Günümüzde herhangi bir büyük işletme, etkin bir şekilde çalışabilmek için yüksek hızlı internete ihtiyaç duyar ve bant genişliği, hızlı internetin çalışmasında önemli rol oynar. Anlık iletişim, bir işletmenin hem kendi içerisinde hem de müşterilerle sürekli bağlantıda kalmasını sağlar. Hiçbir işletme yavaş ağ bağlantısı nedeniyle verdiği hizmetin aksaması riskini göze almak istemez.

İşletmeler için bant genişliği gereksinimleri, geçmiş kullanımlarını değerlendirmeye bağlıdır. Geçmişte ne kadar bant genişliği kullanıldığının belirlenmesinin ardından, bir sonraki adım gelecekte ne kadar bant genişliği

kullanılabileceğinin tahmin edilmesidir. İşletmeler sunduğu hizmetlerdeki artışı karşılayacak kadar bant genişliğine sahip olmalıdır. İhtiyacından daha fazla bant genişliğine sahip olması demek daha fazla maliyet demektir.

Çalışma kapsamında geliştirilen web uygulaması sayesinde ağ trafiği izlenerek kullanılan bant genişliği kayıt altına alınmakta, belirtilen eşik değerlerinin aşılması durumunda loglanmakta ve geleceğe yönelik tahmin yaparak kurum gereksinimleri hakkında bilgi edinilmesi sağlanmaktadır.

1.2. ARAŞTIRMANIN KISITLARI

Çalışmanın tahminleme bölümünde, öğrenci yetiştiren bir kurumun 180 günlük bant genişliği verileri kullanılmıştır. Modellerin eğitilmesinde makine öğrenmesi algoritmalarından Prophet, LSTM ve ARMA kullanılmıştır. Modeller eğitilirken, verilerin azlığı nedeniyle verilerin tamamı eğitim için kullanılmıştır. Bu nedenle mevsimsellik kontrolü yapılamamıştır.

1.3. İLGİLİ ÇALIŞMALAR

Eswaradass ve diğerleri (2005), araştırmalarında ağ performans tahmini için Yapay Sinir Ağına dayalı bir yaklaşım izlemişlerdir. YSA mekanizması klasik izleme dosyalarında test edilmiş ve performans için iyi bilinen NWS sistemi (Network Weather Service) ile karşılaştırmışlardır. Elde ettikleri deneysel sonuçların YSA yaklaşımının NWS'ye göre daha iyi bir tahmin sağladığını belirtmişlerdir.

Talpur ve Kechadi (2016), araştırmalarını bir veri merkezinin gerçek değerleri üzerinde yoğunlaştırmışlardır. Sonuçları Zaman Serisi algoritmalarından ARIMA ve Vector Autoregression modelleri ile karşılaştırmışlardır.

Gehi ve Siddavatam (2014), ağ bant genişliği kullanımını analiz etmişler ve gelecekteki değerleri tahmin etmeye çalışmışlardır. Çalışmalarında Holt Winters algoritmasını ve sinir ağlarını kullanarak sonuçlarını karşılaştırmışlardır. Elde ettikleri bulgularla Holt Winters algoritmasının daha iyi sonuç verdiğini belirtmişlerdir.

Bian ve diğerkleri (2017), ellerinde bulunan internet bant genişliğı veri seti üzerinde LSTM, ARIMA ve AdaBoost-LSTM algoritmalarını test ederek model oluşturmuşlardır. En iyi sonucu sırasıyla; modifiye edilmiş AdaBoost-LSTM, sade AdaBoost-LSTM, ARIMA ve LSTM vermiştir.

Lazaris ve Prasanna (2019), ana omurga ağ trafiğini birkaç ARIMA modelini ve çeşitli LSTM varyasyonlarını karşılaştırmışlardır. Elde edilen sonuçların umut verici olduğunu ve LSTM'nin bağlantı düzeyinde ağ trafiğı modellemesi için iyi bir aday olduğunu belirtmişlerdir.



İKİNCİ BÖLÜM

BİLGİSAYAR AĞLARI

2.1. BİLGİSAYAR AĞLARI VE ÇEŞİTLERİ

Birbirine yakın veya uzak mesafede olan bilgisayar ya da çevre biriminin birbirine bağlanması ile oluşan yapıya bilgisayar ağı denir. Bilgisayarlar arasındaki bağlantı, kablolu veya kablosuz yapıda olabilir (Çubukcu, 1994:12).

2.1.1. Yerel Alan Ağları

Yerel alan ağı; ofis, laboratuvar veya üniversite kampüsü gibi sınırlı bir alandaki bilgi sistem cihazlarını birbirine bağlayan yüksek hızlı bir ağıdır. Yerel ağlar en basit şekilde bilgisayarlar, iş istasyonları, sunucular, yazıcılar ve bunları birbirine bağlayan anahtarlama cihazlarından oluşur. Yerel alan ağları genellikle bir tek kişi veya organizasyon tarafından yönetilirler. Yerel ağlarda Ethernet (10 Mbps), FastEthernet (100 Mbps), GigabitEthernet ve 10 Gigabit Ethernet olmak üzere 4 farklı ethernet hızı vardır (Kamiloğlu, 2015:3). Yerel ağın yapısı, kurumun ihtiyaçlarına ve finansal durumuna bağlıdır.

Yerel ağlarda kablolama çok önemlidir ve genellikle maliyeti uygun olduğu için UTP kablo kullanılır. UTP kablo keşfedilene kadar koaksiyel kablolar kullanılmaktaydı. Ancak, günümüzde yerel ağlarda çok yüksek hızlara ulaşmak istendiğinde fiber optik kablolar da kullanılmaktadır.

2.1.2. Metropolitan (Kentsel) Alan Ağları

Bir şehri kapsayarak kurulmuş iletişim ağlarına veya birbirinden uzak yerlerdeki Yerel Alan Ağlarının (LAN) birbirleri ile bağlanmasıyla oluşturulan ağlara Metropol Alan Ağları (Metropolitan Area Networks, MAN) denilmektedir (Bıyan, 2012:5). MAN bileşenleri arasında yüksek hızlara ulaşmak için fiber optik kablolar kullanılır. MAN'lar kullanıcıları, bir yerel alan ağının kapsadığı alandan

daha büyük ancak geniş alan ağının kapsadığı alandan daha küçük bir coğrafi alan veya bölgedeki bilgisayar kaynaklarıyla birbirine bağlarlar.

MAN'ın çalışma mekanizması İnternet Servis Sağlayıcısına (ISP) benzer ancak MAN tek bir kuruluşa ait değildir. MAN da WAN gibi kullanıcılarına paylaşılan ağ bağlantıları sağlar. MAN'lar çoğunlukla OSI modelinin 2. katmanını olan veri bağı katmanında çalışır.

2.1.3. Geniş Alan Ağları

Yerel veya kentsel ağların birleşmesi ile oluşturulurlar. Şehir, ülke, kıta, hatta dünya çapındaki bilgisayarların birbirleriyle ilişkilendirilmesi sonucunda oluşmuş veya kurulmuş olan bilgisayar ağlarıdır (Reisoğlu, 2008:5). Geniş alan ağı, tek bir konuma bağlı olmayan büyük bir bilgi ağıdır. WAN'lar, bir WAN sağlayıcısı aracılığıyla dünyanın dört bir yanında bulunan cihazlar arasında iletişimi, bilgi paylaşımını ve çok daha fazlasını sağlayabilirler. WAN'lar uluslararası işletmeler için hayati önem taşıyabilir ancak internet dünyadaki en büyük WAN olarak kabul edildiğinden günlük kullanım için de gereklidir.

Geniş alan ağları, birden fazla konumdan ve dünyanın her yerinden cihazları bağlayabilen bir telekomünikasyon ağı biçimidir. Bu ağlar, genellikle servis sağlayıcılar tarafından kurulur ve daha sonra kişiler, işletmeler, üniversiteler veya hükümetler tarafından kiralanırlar. Bu müşteriler, bulundukları yerden bağımsız olarak yerleşik WAN'a eriştikleri sürece veri aktarmak ve depolamak veya diğer kullanıcılarla iletişim kurmak için ağı kullanabilirler. Erişim, sanal özel ağlar (VPN'ler) veya hatlar, kablosuz ağlar, hücresel ağlar veya internet erişimi gibi farklı bağlantılar yoluyla verilebilir.

WAN'lar uluslararası kuruluşlar için temel günlük işlevlerini gecikmeden yerine getirmelerine olanak sağlar. Aynı kuruluşun farklı yerlerinde çalışanlar verileri paylaşmak, iş arkadaşlarıyla iletişim kurmak veya yalnızca o kuruluşun veri kaynağı merkezine bağlı kalmak WAN'ı kullanabilirler. Örneğin, resmi verilerini paylaşmak için farklı şehirlerdeki yüzlerce şubenin birbirine bağlı olduğu bir bankacılık sistemi gibi.

Bir WAN'ın özellikleri:

- Bağlı olan noktalar genellikle coğrafik olarak dağıtılmıştır.
- Bir WAN'a bağlanabilirlik için, verilerin ağ tarafından kabul edilebilir bir biçime konulması sağlamak üzere, modem, yönlendirici, anahtar vs. bir cihaz kullanılması gerekir.
- Hizmetler bir ISP tarafından sağlanır. WAN hizmetleri T1/T3, E1/E3, DSL, Kablo, Çerçeve Aktarımı, ATM, Metro Ethernet veya daha yeni teknolojiler olabilir.
- Altyapının kurulmasından ve yönetilmesinden ISP sorumludur.
- Uç cihazlar, genellikle ethernet kapsüllemesini bir seri WAN kapsüllemesine dönüştürür (Gürtekin, 2012:58).

2.2. AĞ TOPOLOJİLERİ VE ÇEŞİTLERİ

Bir ağdaki, ağ cihazlarının birbirlerine nasıl bağlandıklarını ve nasıl iletişim kurduklarını gösteren yapılarıdır. Ağ topolojileri fiziksel ve mantıksal topoloji olarak ikiye ayrılırlar.

2.2.1. Fiziksel Topoloji

Fiziksel ağ topolojisi, ağa bağlı cihazların fiziksel düzenini gösterir. Fiziksel katmandaki sorunların giderilebilmesi için cihazların fiziksel olarak nasıl bağlandıklarını bilmesi gerekir. Örneğin; kablolu veya donanım sorunları gibi. Bir fiziksel topoloji haritası bilgisayarları, ağ cihazlarını ve ortamlarını belgelemek için bazı simgeleri kullanır. Gelecekte yapılacak kurulum, konfigürasyon değişikliği ve sorun giderme çalışmaları için fiziksel topoloji haritalarının sağlıklı bir şekilde tutulması ve güncellenmesi önemlidir. Fiziksel ağ topolojileri genellikle şunları içerir:

- Cihaz tiplerini,
- Cihazların modellerini ve üreticilerini,
- Konumlarını,

- İşletim sistemi sürümlerini,
- Kablo tipleri ve tanımlayıcılarını,
- Kablolama uç noktalarını (Gürtekin, 2012:94).

2.2.2. Mantıksal Topoloji

Mantıksal ağ topolojisi, bir ağda verilerin nasıl aktarılacağını gösterir. Yönlendirici, sunucu, anahtar, bilgisayar ve güvenlik cihazları gibi ağ öğelerini göstermek için simgeler kullanılır. Donanımlar, adresler, grup bilgileri ve uygulamalar mantıksal topoloji haritası üzerine kaydedilir. Mantıksal ağ topolojileri genellikle şunları içerir:

- Cihaz tanımlayıcıları,
- IP adresleri ve alt ağ maskeleri,
- Arayüz tanımlayıcıları,
- Yönlendirme protokolleri,
- Statik ve varsayılan rotaları,
- Veri bağı protokolleri,
- WAN teknolojileri.

2.2.3. Bus Topoloji

Ağ üzerindeki tüm bağlantılar tek bir hat üzerindedir. Veri bu hattan geçerek tüm bilgisayarlara ulaşır. Gelen veri her kullanıcı tarafından okunur ve kendi adresi ile gelen veriyi alır. Ağ bağlantısı genellikle koaksiyel kablo ile yapılır. Koaksiyel kablonun bilgisayara bağlantısında ise BNC konnektörler kullanılır. Ana omurgayı oluşturan kablonun iki ucuna ise terminatör takılır. Ana omurga kablosunda veya terminatörlerde meydana gelen bir arıza tüm ağın çökmesine neden olur.

2.2.4. Star Topoloji

Bütün bilgisayarların tek bir merkeze bağlanmasıyla oluşturulan topolojidir. Genellikle merkezde hub veya switch adı verilen cihazlar kullanılır. Bus topolojisine

göre daha performanslı çalışan topolojidir. Merkezdeki hub veya switch'te meydana gelecek bir problem bütün ağı etkiler. En büyük avantajı bir kabloda oluşan problem sadece o kabloya bağlı bilgisayarı etkiler. Kurulan ağ elemanlarına göre yüksek hızlar elde edilebilir.

2.2.5. Ring Topoloji

Sistemler dairesel telle birbirlerine bağlanırlar. Her sistem komşu iki sistemle bağlantılıdır. Veri bir yönden iletilir diğer yönden alınır. Her bir sistem, halkada bulunan kendinden sonraki sisteme veri sinyalini düzenleyerek gönderir. Yani veri sinyalinde seviye düşmeleri gözlenmez. Çünkü sinyal, her bir sistemde yeniden üretilir. Yolun kim tarafından kullanılacağı yol üzerinde dolaşan jeton (token) tarafından belirlenir. Jetonu alan sistem veri iletimini yapar. İşlemine bitiren sistem jetonu yola bırakır. Diğerleri jetonun boşalmasını bekler.

2.2.6. Mesh Topoloji

Ağıdaki tüm cihazlar diğer tüm cihazlara bağlıdır. Bant genişliğini fazla kullanırlar. Ağın çökme ihtimali çok düşüktür. Fazla kablo kullanımı olur. Yerel ağlar için çok maliyetlidir. Genellikle geniş alan ağlarında kullanılır.

2.3. AĞ BAĞLANTI CİHAZLARI

Çeşitli yapıda ve uzaklıkta veya büyüklükte ağları veya bilişim aygıtlarını birbirine bağlamada ağ bağlantı cihazları kullanılır.

2.3.1. Ağ Kartı

Bilişim cihazları ile ağ arasında iletişimi sağlamak için kullanılan arabirim kartıdır. Bu kart, ağa gönderilecek verileri alır daha sonra paketlere böler ve varış yerine iletir. Tam tersi işlem olarak da ağdan gelen paketleri orijinal veri yapısına geri çevirir. Veri transferlerinde yol boyunca veri kaybı olup olmadığını anlamak için

hata kontrolü yapar. OSI katmanlı modelinin 2. katmanı olan veri bağı katmanında çalışır. Günümüzde kablolu veya kablosuz ağ kartları yaygın olarak kullanılmaktadır.

2.3.2. Repeater (Tekrarlayıcı)

Repeater, bir portundan aldığı elektrik sinyallerini binary koda çevirerek tüm paketleri tekrarlar ve diğer portuna yollar. Kendisine gelen zayıf sinyali, tekrar temiz ve güçlü sinyale dönüştürdüğü için bu anlamda sadece yükselteç değildir. Kablo mesafesini uzatmada kullanılır. OSI katmanlı modelinin 1.katmanı olan fiziksel katmanda çalışır.

2.3.3. Hub

En basit ağ cihazıdır ve repeater'la hemen hemen aynı özelliklere sahip olup, çok portlu repeater olarak düşünülebilir. Hub'a bağlanan cihazlara ortak ve paylaşımlı bir yol sunar. Aynı anda haberleşmek isteyen cihazlar ortak yolun boşalmasını beklerler. Bir porttan gelen paketler nereye gideceğine bakılmaksızın tüm portlara gönderilir. Bu da ağda yavaşlamaya neden olmaktadır. Günümüzde UTP kablolu kullanılabilecek ağlarda kablo mesafesini uzatmak için repeater olarak kullanılmaktadır. Hub'lar fiziksel olarak star topolojisini mantıksal olarak bus topolojiyi kullanırlar. Hub'lar da repeater'lar gibi OSI katmanlı modelinin 1.katmanı olan fiziksel katmanda çalışırlar.

2.3.4. Bridge (Köprü)

Bridge (köprü), birbirinden bağımsız fakat aynı protokolü kullanan iki veya daha fazla ağı birbirlerine bağlamada kullanılan cihazdır. İki farklı yerde iki farklı bilgisayar birbirine bridge ile bağlandığında sanki aynı networkteymiş gibi görünürler. Bridge'ler katmanlı modelinin 2.katmanı olan veri bağı katmanda çalışırlar.

2.3.5. Switch

Switch'ler ağı bağlı cihazlar arasında anahtarlama yöntemiyle bağlantı kurulmasını sağlayan cihazlardır. Switch'ler ilk açıldığında hub gibi çalışırlar ancak zamanla MAC adres tabloları doldukça anahtarlama yapmaya başlarlar. Tüm cihazlar Hub'ın aksine aynı anda ve daha hızlı haberleşebilirler. Switch'te veri tüm portlara iletilmez, hedef MAC adresine bakılarak doğrudan iletilmesi gereken cihaza iletilir ve bu da ağda yavaşlamayı engeller. Switch kullanılan ağlar yıldız topolojisini kullanırlar. Switch'ler OSI katmanlı modelinin 2.katmanı olan veri bağı katmanında çalışırlar. Ancak anahtarlama özelliğinin yanında yönlendirme özelliği de olan switchler günümüzde üretilmektedir. Bu cihazlar 3.katman olan ağ katmanında çalışırlar.

2.3.6. Router

Temel işlevi yönlendirme olan ve farklı teknolojilere sahip ağları birbirine bağlayan cihazdır. LAN'ları WAN'a bağlarlar. Router'lar işletim sistemine sahiptirler ve programlanabilirler. Bu sayede IP yönlendirme tablosu ve MAC adres tablosu tutabilirler. Yönlendirme tablolarında hedef cihazların IP adresleri tutulur ve bu yüzden veri paketlerini seçtiği en hızlı yoldan hedefe yollayabilirler. Router'lar hatlardaki trafiği ve bant genişliğini kontrol edebilirler. OSI katmanlı modelinin 3.katmanı olan ağ katmanında çalışırlar.

2.3.7. Firewall (Güvenlik Duvarı)

Firewall, özel bir ağı gelen ve giden trafiği izleyen ve belirli kurallara göre belirli trafiğe izin verip vermemeye karar veren bir ağ güvenlik cihazıdır. Güvenlik duvarları, denetlenen ve güvenilen iç ağlar ile güvenilmeyen dış ağlar arasında bir engel oluşturur ve iç ağın dış etkenlerden korunmasını sağlar.

ÜÇÜNCÜ BÖLÜM

RAPORLAMA İLE İLGİLİ KAVRAMLAR

3.1. İŞ ANALİTİĞİ

İş analitiği, yakın tarihte hem iş hem de akademik çevrelerde popülerlik kazanan nispeten yeni bir terimdir. İş analitiği kavramı “Genel anlamda matematik, istatistik, makine öğrenmesi ve ağ bilim yöntemlerini çeşitli veriler üzerinde kullanıp, uzman bilgisini de bu sürece dâhil edip bu verilerden bilgi keşfetmeye çalışan bir sanat ve bilim dalıdır” (Delen ve Ram, 2018:2). Bu nedenle, iş analitiği karar verme ve problem çözmede bir kolaylaştırıcı olarak düşünülebilir. Genel olarak bakılırsa, analitik basitçe “verilerdeki anlamlı kalıpların keşfi” olarak tanımlanabilir. Büyük veri çağında yaşadığımız için, analitik tanımları çoğunlukla büyük hacim ve çeşitlerde verilere odaklanır. Mevcut analitik tanımlarının çoğu öncelikle veri odaklıdır. Ancak çok az veri bulunan veya hiç veri bulunmayan analitik uygulamaları da mevcuttur. Bu tür analitik projelerde genellikle uzman bilgisine dayanan matematiksel modeller kullanılmıştır. İş analitiği, karmaşık iş sorunlarına çözüm geliştirmek için kendi araçlarını, tekniklerini ve ilkelerini kullanan özel bir analitik alt kümesidir. Şirketler, işletme performanslarını tanımlamak, tahmin etmek ve optimize etmek için analitiği işletme verilerine uygularlar.

3.1.1. İş Analitiğinin Artan Önemi

Dünya üzerinde her gün milyonlarca bit veri üretilmektedir. Veri tabanları bu verileri gigabaytlarca ve hatta terabaytlarca alanlarda depolamaktadır. Anlamları yorumlanmadıkça bu büyük boyutlarda verileri depolamanın hiçbir anlamı yoktur. Günümüzde öyle bir çağda yaşıyoruz ki depoladıkları verileri sadece akıllıca kullananlar başarıya ulaşabilmektedir. Şirketler bu verileri düzgün bir şekilde analiz edebilirlerse, yararlı enformasyon ve bilgiler elde edebilirler. Anlamlı bilgiler, şirketlerin karlılığı için kullanıldığında, diğer şirketlere göre rekabet avantajı sağlayacaktır.

Veri hacmindeki büyük artış neticesinde kanıta dayalı uygulamalara odaklanma artmıştır. Bu da analitik tekniklerini kullanma gerekliliğini doğurmuş ve iş analitiğinin ortaya çıkmasına yol açmıştır (Acito ve Khatri, 2014). İş analitiği, işlemler ve analiz arasında iki yönlü bir döngü oluşturur. Bu döngü verilerin analiz edilmesini ve analiz sonuçlarının ticari işlemlerde kullanılmasını sağlar. Bu döngüde geliştirilerek ortaya çıkan bilgiler, işletme kullanıcıları tarafından günlük faaliyetlerde kullanılırlar (Kohavi, Rothleder ve Simoudis, 2002).

Hızlı Tüketim Ürünleri şirketlerinden biri olan P&G, başarılı bir iş analitiği entegrasyon öyküsüne sahiptir (Murphy, 2012). P&G, 180 ülkede 127.000 çalışanı ve 300'den fazla markasıyla faaliyet göstermektedir. P&G'nin günde yaklaşık 4 milyar işlemi bulunmaktadır. İş süreçlerini “dijitalleştirmek” ve karar alma mekanizmasını merkezileştirmek için “Business Sufficiency, Business Sphere and Decision Cockpits” yani “İş Yeterliliği, İş Alanı ve Karar Kokpitleri” adlı analitik sistemleri başlattı. Bu analitik çözümler binlerce kullanıcıya hizmet vermektedir. P&G, bu sistemi kullanarak analitik ve veri tabanlı karar almayı desteklemektedir. Çalışanlar birçok iş sürecini geliştirmiş ve tasarruf sağlanmıştır. O zamana kadar, iş analitiğinin öneminin farkında olmayan yöneticiler, şimdilerde projeleri için derin analizler kullanmaya çalışmaktadırlar (Davenport ve Harris, 2007:7).

Başka bir örneği Facebook yapmaktadır. İnsanların olası tercih modellerini tahmin etmek için büyük bir sosyal ağ kullanmaktadır. Çok sayıda demografik bilgi ve kullanıcı aktivitesini işleyebilme kabiliyetine sahiptir. Facebook'taki veri bilimcileri, bağlantılara ve iletişim modellerine bakarak ortaya çıkacak olası bir romantik ilişkiyi bile tahmin edebildiklerini söylüyorlar. Her ne kadar inanması zor görünse de iş analitiği ile bu mümkündür (Mishra, 2017).

ABD’de 2015 yılında iş analitiğinde büyük harcama yapan sektörler sırasıyla 6,4 milyar dolarla finans, 2,8’er milyar dolarla yazılım ve hükümet, 1,2 milyar dolarla medya ve iletişim, 800 milyon dolarla kamu hizmetleridir. Araştırmacılar, bu sektörlerin 2020 yılına kadar iş analitiğine bir önceki yıla göre yatırımlarını %22 ila %54 arasında artırmasını tahmin etmektedirler. Veriler, analitiği kendi yararlarına kullanan şirketlerin; finansal performans için ilk çeyreğe göre iki kat daha yüksek, zamanında karar verme olasılığının beş kat daha yüksek, kararlarını ve planlarını uygulama olasılıklarının üç kat daha yüksek olduğunu göstermektedir. (Villanova

Üniversitesi İş Makaleleri). Sonuç olarak bakıldığında, sektörlerin iş analitiğine verdiği önemin her geçen gün artarak daha da büyümesi beklenmektedir.

3.1.2. İş Analitiğinin Türleri

İş analitiği hakkında çalışmalar incelendiğinde iş analitiğini dört bölüme ayırmak ya da diğer bir deyişle dört boyutta incelemek en uygun yaklaşım olarak görülmektedir (Schniederjans, Schniederjans ve Starkey, 2014:4). Bu bölümlerden ilk ikisi açıklayıcı özelliğe (descriptive (tanımlayıcı) ve diagnostic (teşhis edici)), diğer ikisi ise modelleme ve matematiksel hesaplama özelliğine (predictive (öngörücü) ve prescriptive (yönlendirici)) sahiptir. Bu bölümler aşağıdaki gibi özetlenebilir (Delen ve Zolbanin, 2018).

3.1.2.1. Tanımlayıcı Analitik

Tanımlayıcı analitik, daha çok verileri özetlemek ve raporlamakla ilgilidir. Günümüzde kuruluşların %85'i en temel analitik biçimi olan tanımlayıcı analitiği kullanmaktadır. Bu tür analitik, şu anda veya geçmişte olanlara yönelik olarak kullanılır. Tanımlayıcı analitiği anlatmanın en basit yolu “Ne oldu?” veya “Ne oluyor?” sorularını sormaktır. Bu tür analitikte, şirketler geleceğe nasıl yaklaşacaklarını güncel veya geçmiş verileri analiz ederek görmeye çalışırlar. Tanımlayıcı analitiğin temel amacı, geçmişte belirli bir başarı veya başarısızlığı bulmaya çalışmaktır.

3.1.2.2. Teşhis Edici Analitik

Teşhis analitiği, geçmiş ve güncel verileri inceleyerek "Bu neden oldu?" soruna cevap arar (Evans, 2013). Teşhis analitiği, verilerden elde edilen bilgileri göstermek için tanımlayıcı analitikte de olduğu gibi görselleştirme tekniklerini kullanır. Ancak teşhis analitiği sorunun temelindeki nedenleri açıklamaya odaklanırken, tanımlayıcı analitik sadece mevcut durumu gösterir. Teşhis analitiği genellikle işletme çevresi, müşterileri, yeni bir ürünle ilişkili riskleri, vb. gibi

stratejik kararları keşfetmede kullanılır (Banerjee vd., 2013). Veri analistleri, kalıpları, eğilimleri ve korelasyonları bulmak için bu analitik türünü incelerler. Teşhis analitiği, regresyon analizi, anomali tespiti, kümeleme analizi gibi veri madenciliği teknikleri de kullanılarak yapılabilir.

3.1.2.3. Öngörücü Analitik

Öngörücü analitik, geçmiş verilerdeki ilişkileri tespit ederek ve gelecek zaman ilişkilerini ayarlayarak, geleceği tahmin etmek için geçmiş verileri kullanır (Evans ve Lindner, 2012). Eckerson (2007) süreçler hakkında tahmin yapma, müşteri davranışını daha iyi anlama, iş fırsatlarını ve olası sorunları ortaya çıkmadan belirleme gibi alanlarda şirketler üzerinde öngörücü analitik uygulamalarını açıklamıştır. Bu tür önemli görevler için öngörücü analitik kullanıldığında, kullanılan sistemin tahmine dayalı doğruluğu sağlanmalıdır. Shmueli ve Koppius (2011) MIS Quarterly (MISQ) ve Information Systems Research (ISR) gibi en güvenilir dergilerde öngörücü analitikle ilgili çalışmaları incelemişler ve araştırmacıların tahmin doğruluğunun, çoğunlukla örnekleme tekniklerine mi, yeterli tahmin yöntemlerine mi yoksa p değeri ve belirleme katsayısına (R^2) mı dayalı olduğunu göstermeye çalışmışlardır. Tüm bu kıstasların öngörücü performans üzerinde yüksek etkisi olan kriterler olduğu belirtilmelidir. Bu tür araştırmaların yürütülmesi, tahmine dayalı analitik içeren sistemlerin verimliliği için önemlidir. Çünkü şirketlerin tahmine dayalı modellerinin faydaları, tahmin doğruluğu ile büyük ölçüde ilişkilidir (Shmueli ve Koppius, 2011). Bu nedenle, öngörücü analitikte herhangi bir sistem için tahmin doğruluğu yüksek, tahmin hatası düşük tutulmalıdır.

3.1.2.4. Yönlendirici Analitik

İş analitiğinin son türü, karmaşık hedefler, gereksinimler ve kısıtlamalar altında iş performansını iyileştirmek için bir dizi analizi barındıran yönlendirici analitiktir. Yönlendirici analitik, öngörülen gelecek için en uygun planlama kararlarının alınmasını ve “Ne yapalım? Neden yapalım?” sorularını içerir (Evans, 2012). Yönlendirici analitikte ana bileşenler optimizasyon modelleme, simülasyon

modelleme, çok kriterli karar modelleme, uzman sistemler ve grup destek sistemleridir. Bu analizin en önemli çıktısı, iş kararlarının mümkün olan en iyi seyrini sağlayan bilgi kümesidir (Delen ve Demirkan, 2013). Yönlendirici analitiğin ana görevlerinden biri pazarlama, finans ve operasyonlar da dahil olmak üzere birçok farklı iş alanında en iyi alternatifleri optimize etmektir. Gelirleri en üst düzeye çıkarmak için şirketler, en iyi fiyatlandırma kararlarını ve en cazip reklam stratejisini belirleyebilirler veya risk yönetimi portföyündeki çeşitli yatırım seçenekleri arasından en iyi kombinasyonları seçebilirler (Evans ve Lindner, 2012). Optimizasyon modellemesinin devamı olarak duyarlılık analizi, analizin öngörücü bileşeninin, yani çoklu regresyon modelinin doğruluğunu sağlar. Bu nedenle yönlendirici bileşeni, yani optimizasyon modelini etkiler (Kawas, vd., 2013). Regresyon modeli ne kadar doğru olursa, yönlendirici önerileri olan optimizasyon modeli de o kadar güvenilir çözümler sağlayacaktır. Duyarlılık analizinin amacı, regresyon parametrelerindeki değişiklikler üzerindeki yönlendirici önerilerin sağlamlığını kontrol etmektir.

Yönlendirici analitik ile ilgili bir diğer önemli analiz çok kriterli karar modellemesidir. Genellikle tedarikçi seçim ve değerlendirme süreçlerinde yaygın olarak kullanılmaktadır (Ho, vd., 2010). Firmalar fiyat, maliyet, ürün kalitesi, teslimat hızı gibi sayısız nicel ve nitel faktörle ilgilenmektedirler. Çok kriterli karar modelleme yaklaşımı sayesinde şirketler tedarikçi seçimi ve değerlendirme problemini etkin bir şekilde çözebilirler (Ho, vd., 2010).

Yönlendirici analitik, kâr, maliyetler, hizmet kalitesi ve risk yönetimi gibi iş hedefleri üzerinde çok büyük bir etkiye sahip olduğundan, en gelişmiş analitik türüdür (Gröger, vd., 2014). Bu büyük etkinin ana nedeni, şirkete çeşitli süreçlerde optimizasyon sağlamasıdır.

3.2. İŞ ZEKÂSI

3.2.1. İş Zekâsı Kavramı

İş zekâsı farklı insanlar için farklı şeyler ifade eder ve iş zekâsının birden fazla tanımı bulunmaktadır. Bazıları bunun sadece veri raporlama ve veri görselleştirme ile sınırlı olduğunu düşünmektedir. Bazıları ise işletme performans

yönetimi, veri çıkarma, dönüştürme ve entegrasyon ile istatistiksel analiz ve veri madenciliğine yardımcı olduğunu düşünmektedir. Vitt ve ark. (2002), iş zekâsını “Bir kuruluşun hangi bilginin yararlı ve kurumsal karar alma süreciyle ilgili olduğunu tanımlamasına izin veren bir yönetim yaklaşımı” olarak tanımlamaktadır. Howson (2007), iş zekâsını “Bir kuruluşun tüm düzeylerindeki kişilerin işletmeyi yönetmek, performansı artırmak, fırsatları keşfetmek ve verimli bir şekilde çalışmak için verilere erişmesine, etkileşimde bulunmasına ve analiz etmesine olanak tanıyan” bir etkinlik olarak tanımlamıştır. Bu tanımlarda bilgi sistem teknolojilerinin iş zekâsında oynadığı rolün göz ardı edildiği görülmektedir. Golfarelli ve ark. (2004), iş zekâsını “Verileri enformasyona ve daha sonra karar vermeyi kolaylaştırmak için bilgiye işleyen bilgi sistemleri” olarak tanımlamaktadır. Loshin (2003), “şirketin enformasyon varlıklarından keşfedilmiş olan bilgilerden faydalanması için tasarlanmış bir dizi araç ve metodoloji” olduğunu belirtmektedir. Hancock ve Toren (2005), iş zekâsını “bir kurumdaki geniş çapta ayrılmış tüm verileri enformasyona ve nihayetinde bilgiye dönüştürme hedefine ulaşmak için tasarlanmış bir dizi kavram, yöntem ve teknoloji” olarak tanımlamaktadır. Davenport ve Harris (2007) iş zekâsının iş analitiğini kapsadığını ve “iş performansını anlamak ve analiz etmek için verileri kullanan teknolojiler ve süreçler kümesi” olarak değerlendirmiştir. Tüm bunlar işletme performansını geliştirmek için, ham verilere erişip, anladıktan sonra analiz ederek işlenebilir bilgilere dönüştürmek amacıyla yapılmaktadır (Azvine, vd., 2005).

Kurumlar, iş zekâsı araçlarını ve yöntemlerini sadece geleceği öngörmek için değil, aynı zamanda geçmişi öğrenmek ve anlamak için de kullanırlar (Marjanovic, 2007). İş zekâsı, bir işletme hakkında veri ve bilgi toplamak ve bunları analiz etmek ve de daha bilinçli iş kararları verilmesine yardımcı olmak için faydalanılan uygulamaları ve teknolojileri tanımlamak için kullanılan bir iş yönetimi terimidir (Nicholls 2006). Turban, vd. (2008) iş zekâsının temel amacının karar vermeyi desteklemek için daha fazla bilgi edinmek ve işletme verileriyle etkileşimi geliştirmek olduğunu belirtmektedir.

Bir kuruluş, hem operasyonel hem de stratejik düzeyde, yönetsel karar almayı geliştirerek rekabet avantajı elde edebilir (Vuori, 2006). 2003 yılında Nigel Pendse tarafından, 48 ülkede 3000 çalışandan oluşan kapsamlı bir anket kullanılan

çalışmada, iş zekâsının olası faydaları tespit edilmiştir (Tablo 1) (Thompson 2004). Sunulan sonuçlardan da anlaşılacağı üzere, raporlama ve karar vermedeki gelişmeler en önemli faydalar olarak görülmektedir.

Tablo 1: İş Zekâsının Faydaları

Faydalar	Şirketlerin Sağladığı Fayda
Daha hızlı ve daha doğru raporlama	%81
Geliştirilmiş karar verme	%78
Geliştirilmiş müşteri hizmetleri	%56
Gelir artışı	%49
BT dışı maliyetlerde tasarruf	%50
BT maliyetlerinden tasarruf	%40

Kaynak: Thompson, 2004.


“Doğru bilginin doğru zamanda doğru yerde ve doğru biçimde olması gerekir” (Choo, 2002:42) bu ifade, iş zekâsının hedefleri hakkında konuşurken yaygın olarak kullanılan bir ifadedir. Bilgi açığı, toplanan bilgi ile karar vericinin kurumsal bilgi yönetiminin durumunu tanımlayan bilgi ihtiyaçları arasındaki bir boşluktur (Pirttimäki, 2007:42). Bilgi arz ve talebi arasındaki bu boşluk, ilk olarak bir yöneticinin bilgi talebinin belirlenip bu ihtiyaçların mevcut bilgi durumuyla karşılaştırılması olarak tanımlanabilir (Laitinen, 2009:553). Bu boşluğun azaltılması için kurumsal iş zekâsı faaliyetlerinin bu ihtiyaçları karşılayacak şekilde daha iyi hedeflenmesi gerekir. İş zekâsı yeteneklerinin ve süreçlerinin işletme operasyonlarını ve karar almayı destekleyebilmesi için belirli bir organizasyon kültürü ve üst yönetimden desteğe ihtiyaç duymaktadır (Watson ve Wixom, 2007:98).

İş zekâsının rekabet avantajı olarak uygulanabilirliği bir şirketin büyüklüğüne bağlı değildir. Kurumun amaçlarını, hedeflerini ve stratejisini ilerletmek için her büyüklükteki şirkette kullanılabilir (Thierauf, 2001:16). Bu faaliyet her zaman sistematik ve bilinçli olmasa da, tüm kuruluşlarda bir düzeyde iş zekâsı uygulanmaktadır. İş zekâsı kullanımı, örgütsel ihtiyaçların ve gelişmenin sonucunda da zamanla değişmektedir. İş zekâsının sağladığı avantajlar nedeniyle gelecekte çok daha fazla kurum, kuruluş ve şirket tarafından kullanılması beklenmektedir.

3.2.2. İş Zekâsı Mimari Yapısı

İş zekâsının başarılı olabilmesi için, işletmeye bir bütün olarak faydalı olması gerekir. Sistem tasarlanırken, iş zekâsı kullanıcı gruplarının ihtiyaç ve bakış açılarının görülebilmesi için farklı çıkar gruplarından da insanlar dâhil edilmelidir (Sharda, vd. 2014:40). İş zekâsı için temel ilkeler tüm kuruluşlarda aşağı yukarı aynı olsa da, iş zekâsı mimarisi her zaman kuruluşa özeldir. Watson'a (2009) göre, iş zekâsı mimarisi organizasyonel hedeflere bağımlıdır. İş zekâsı için üç temel hedef türü tanımlanabilir: bağımsız veri merkezleri kullanarak departman düzeyinde odaklanmış ihtiyaçları desteklemek, mevcut ve gelecekteki organizasyonel iş zekâsı ihtiyaçlarını veri ambarı yardımıyla desteklemek, yeni iş modellerinin ve stratejisinin uygulanmasını sağlayarak kurumsal dönüşümü desteklemektir (Watson, 2009:491).

Şekil 1: İş Zekâsı Mimarisi



Kaynak: Rausch vd., 2013:5.

İş zekâsı mimarisi, veri, analitik ve sunum katmanlarını içermektedir (Şekil 1). İş zekâsı süreci verilerin, analiz için veri ambarına alınması ve verilerin karar almak için veri ambarından çıkarılması şeklinde basitleştirilebilir (Watson ve Wixom 2007:96). Veriler birden fazla dâhili ve harici kaynaktan aktarılarak veri ambarlarında saklanır. Bu aktarım, kuruluşun analiz ihtiyaçlarına göre yapılır ve analitik katmanında birleştirilir (Chaffey ve White 2011:399). Son olarak sunum katmanında, bilgi genellikle bir iş zekâsı uygulaması kullanılarak kullanıcılara sağlanır.

3.3. MAKİNE ÖĞRENMESİ

Makine öğrenmesi, istatistiksel ve matematiksel işlemler ile hâlihazırda elde bulunan verilerden çıkarımlar yaparak tahmin yapılabilmesi için sistemin modellenmesidir. Makine öğrenmesi, yapay zekânın bir alt uygulamasıdır.

Makine öğrenmesinde genellikle geçmişe yönelik veya örnek veri setleri bilgisayarlara tanımlanır ve bilgisayarlardan yeni oluşacak durumlara karşı çıkarımlar veya tahminler yapması beklenir. Eğitilen makine, kullanılan algoritmaya göre veri yapısını anlar ve bir model oluşturur. Bundan sonra girilecek yeni verilere makine, oluşturulan modele göre cevap verecektir.

Makine öğrenmesi, veri analizi, matematik, istatistik ve yapay zekâ birbirleriyle ilişkilidir. Lojistik, üretim, satış, pazarlama, insan kaynakları, finans ve sağlık hizmetleri makine öğrenmesinin başlıca kullanım alanlarındandır.

Makine öğrenmesi aynı zamanda insan öğrenme davranışlarını taklit etmeye çalışan algoritmaların tasarımı ve gerçekleştirilmesi ile de ilgilenmektedir. Bilim insanlarının bu kapsamda amacı, makineleri insanlar gibi düşünüp davranabilen sistemler haline getirmeye çalışmaktır. Son yıllarda tanık olunan görev robotları, satranç oynayan bilgisayarlar ve otonom uçabilen insansız hava araçları bu alanlarda yapılmış çalışmaların günlük yaşantımızda kullanılan bazı ürünlerindendir.

Makine öğrenmesinin amacı, kullanılan modelin en iyi performansı sağladığı parametre değerlerinin bulunması, tahmin özelliği güçlü ve karar vermeye yardımcı bir model olup olmadığı ve veriden bilgiye ulaşmakta kullanılabilmesidir (Alpaydın, 2014).

Bir makine öğrenmesinin davranışı nasıl değiştireceği şu şekilde ifade edilebilir (Mitchell, 1997):

“Eğer bir bilgisayar programının T görevlerindeki, E deneyimi ile ölçülen P performansı yükseliyorsa, T görevlerinin sınıf doğruluğu ve ölçülen P performansına göre o bilgisayar programı E deneyimini öğrendiği söylenir.”


Bahsi geçen durum örnek olay üzerinde incelenirse:

- T görevi, ağlar üzerindeki bant genişliği ölçümünü,
- P performansı, bant genişliğinin gerçek değerlere yakın olarak tahmin edilmesi,

- E deneyimi, programın geçmişten günümüze kadar yaptığı bant genişliği ölçüm kayıtlarını içeren veri tabanıdır.

Makine öğrenmesinin temel uygulama modeli Şekil 2’de gösterilmiştir.

Şekil 2: Makine Öğrenmesinin Temel Uygulama Modeli



Kaynak: Yazar tarafından derlenmiştir.

Makine öğrenmesi verilerin tanımlanması ile başlar. İlk olarak sistemde hangi tür verilerin kullanılacağı ve neler elde edilmek istendiği belirlenir. Ardından verilerin sisteme öğretilmesi için gerekli hazırlıklar yapılır. Bu aşamada modelin veriyi tanıyabilmesi için varsa verideki hatalar ve boşluklar temizlenir. Daha sonra veriler, eğitim ve test verisi iki parçaya ayrılır. Eğitim verisi, sistemin tahminleme için kullanacağı algoritmayı bulabilmesi için öğrenmesi gereken veriden meydana gelir. Eğitim verisi sisteme öğretildikten sonra sistemden test verilerini tahminlemesi beklenir. Bu tahmine bakılarak gerçek çıktılar ile tahmin sonucu karşılaştırılarak sistem tahminlemesinin ne kadar başarılı olduğu incelenir.

Makine öğrenmesinin sunduğu avantajlar şunlardır (Brink, Richards ve Fetherolf, 2016: 16):

- **Doğruluk:** Makine öğrenimi, problem çözümü için en iyi sınıflandırma modelini seçmede veriyi kullanır. Ne kadar çok veri toplanırsa doğruluk da veriye bağlı olarak o kadar artabilir.
- **Otomatiklik:** Veriler sisteme yüklenince model, otomatik olarak yeni kalıplar öğrenebilir. Bu durum kullanıcılara, makine öğrenmesi ile çalışırken otomatik bir iş akışına sahip olmalarını sağlar.
- **Hızlılık:** Makine öğrenmesi, sistemlerin anlık tepki vermesine olanak sağlar ve yeni veri akışı geldiğinde milisaniyeler içinde cevaplar üretebilir.
- **Özelleştirilebilirlik:** Verilerden kaynaklanan birçok sorun makine öğrenmesi yöntemleri ile giderilebilir. Makine öğrenmesinde modeller, sisteme girilen verilerle oluşturulur ve sorun ne olursa olsun çözümünü bulmak için yapılandırılabilir.
- **Ölçeklenebilirlik:** Problemler büyüdükçe makine öğrenmesi, artan verileri işlemede kolaylıkla ölçeklenebilir.

Makine öğrenmesi yöntemleri Şekil 3'te gösterilmiştir.

Şekil 3: Makine Öğrenmesi Yöntemleri

Denetimli Öğrenme		Denetimsiz Öğrenme
Sınıflandırma	Regresyon	Kümeleme
Lojistik Regresyon	Doğrusal Regresyon	K-Ortalamalar
K-En Yakın Komşu	Polinom Regresyon	Apriori/Birliktelik
Destek Vektör Makineleri	Bayes Ağları	Genetik
Naive Bayes		Hiyerarşik Kümeleme
Karar Ağaçları		Yapay Sinir Ağları
Yapay Sinir Ağları		

Kaynak: Yazar tarafından derlenmiştir.

- Denetimli Öğrenme: Gerçek hayatta bazı verilerin sınıfları belli, bazılarının ise sınıfları belli değildir. Denetimli öğrenmede amaç, sınıfı belirli verilerin eğitilmesi sonucunda sınıfı belirli olmayan verilerin doğru sınıflandırılmaya çalışılmasıdır. Makine öğrenme yöntemleri ile her biri ayrı ayrı kendi sınıfıyla etiketlenmiş veriler denetimli öğrenme ile eğitilir. Yeni verilerin beklediğimiz çıktıya en yakın sonucu üretmesi için bir model oluşturulur. Modelle elde ettiğimiz sonuç ile gerçekte olmasını istediğimiz sonuç arasındaki fark, hata oranı olarak kabul edilir ve bu hata oranı, minimuma indirilmeye çalışılır. Böylece sınıfı belirsiz veriler en yüksek doğruluk oranıyla sınıflandırılmış olur. Regresyon ve sınıflandırma yapılırken denetimli öğrenme tercih edilir. Örnek olarak kimin yazdığı belli olmayan bir kitabın hangi yazara ait olduğunun bulunabilmesi için makine öğrenmesi uygulanarak sisteme farklı kitapların sahip olduğu cümle uzunluğu, sık kullanılan bağlaçlar, yazarlarının düşüncelerini içeren anahtar kelimeler, kitapların konuları vb. değişkenlerin girilmesi verilebilir. Burada önemli olan, aslında kitap hangi yazarınsa, sisteme öğretilenler arasında bahsi geçen yazara ait kitap bilgilerinin de eklenmiş olmasıdır. Aksi halde sistem, gerçek yazara ait bilgiye sahip olmayacak ve doğru sonuca ulaşamayacaktır (Conneau, vd., 2017).
- Denetimsiz Öğrenme: Bu öğrenme yönteminde sisteme girilen veriler üzerinden bir çıkarım yapılması beklenir. Sistem, verileri girilen değişkenler arasındaki ilişkiye bağlı olarak gruplara ayırır ve çıktı değişkenlerini oluşturur. Veriler arasında bulunan benzerliklere göre sınıflandırma tahminlemesi yapılır. İnternette A malzemesini alan müşteriler yanında genellikle B malzemesini de alıyorsa, B malzemesinin satış rakamlarının tahmin edilebilmesi için A malzemesinin verilerinden yararlanılabilmesi denetimsiz öğrenmeye örnek olabilir.

3.4. ZAMAN SERİLERİ

3.4.1. Zaman Serisi Kavramı

Bir zaman serisi, zaman içinde ardışık olarak alınan gözlemler dizisidir. Birçok veri kümesi zaman serisi olarak görünebilir. Zaman serileri saatlik, günlük, haftalık, aylık veya yıllık bazda olabilirler. Örnek olarak; bir fabrikadan gönderilen malların aylık sırası, haftalık trafik kazası sayısı, günlük yağış miktarları, kimyasal bir işlemin verimine ilişkin saatlik gözlemler verilebilir (Box vd, 2015). Ekonomi, işletme, mühendislik, doğa bilimleri (özellikle meteoroloji) ve sosyal bilimler gibi alanlarda zaman serileri kullanılmaktadır. Bir zaman serisinin en önemli özelliği, gözlemlerin birbirine bağımlı olmasıdır. Zaman serisi, matematiksel olarak $x(t)$, $t = 0, 1, 2, \dots$ vb. vektörler kümesi olarak tanımlanır; burada t , zaman periyotlarını temsil eder. Ayrıca, zaman serilerindeki bir olaydan alınan ölçümler uygun bir sıraya göre yapılır. Tek değişkenli zaman serileri tek bir değişkenin kayıtlarını içerir. Ancak, kayıtların birden fazla değişken içerdiği durumlarda bu seri çok değişkenli zaman serisi olarak adlandırılır. Pawlak (1982), zaman serilerinin, sürekli veya ayırık olabileceğini belirtmiştir.

Zaman serisi modellerinin temel amacı, serinin yapısını gösteren uygun bir model geliştirmek için zaman serisinin geçmiş gözlemlerini toplamaktır. Geçmiş gözlemlerden geleceğe yönelik değerler üretmeye zaman serisi tahmini adı verilir. Gelecekteki değerlerin başarılı bir şekilde tahmin edilebilmesi için daha fazla veriyle en uygun model oluşturulmalıdır. Zira tahmin modellerinde doğruluğu artırmak için araştırmacılar yıllar boyunca girişimlerde bulunmuşlardır.

3.4.2. Zaman Serilerinde Performans Değerlendirme Yöntemleri

3.4.2.1. Ortalama Hata Karesi (MSE)

$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2$$

şeklinde formülize edilmektedir ve önemli özellikleri aşağıda sunulmuştur.

- Tahmin edilen değerlerin ortalama kare sapmasının ölçümüdür.
- Zıt işaretli hatalar birbirini dengelemez, MSE tahmin sırasında oluşan hatalar hakkında genel bir fikir verir.
- Tahmin sırasında meydana gelen aşırı hataları panelize eder.
- MSE, genel hatanın yönü hakkında herhangi bir fikir vermez.
- MSE, ölçek değişimine ve veri dönüşümlerine duyarlıdır.
- MSE, genel tahmin hatasının iyi bir ölçeği olmasına rağmen, diğer ölçümler kadar sezgisel ve kolayca yorumlanabilir değildir (Adhikari ve Agrawal, 2013).
- Her zaman pozitif değerlidir ve literatürde sıfıra yakın olan tahminlerin daha iyi performans gösterdiği görülmektedir.

3.4.2.2. Ortalama Karesel Hatanın Karekökü (RMSE)

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2}$$

şeklinde formülize edilmektedir ve önemli özellikleri aşağıda sunulmuştur.

- RMSE, hesaplanan MSE'nin karekökünden başka bir şey değildir.
- MSE'nin tüm özellikleri RMSE için de geçerlidir (Adhikari ve Agrawal, 2013).
- Her zaman pozitif değerlidir ve literatürde sıfıra yakın olan tahminlerin daha iyi performans gösterdiği görülmektedir.
- RMSE değerinin sıfır olması modelin hiç hata yapmadığı anlamına gelir.

3.4.2.3. Ortalama Mutlak Hata (MAE)

$$MAE = \frac{1}{n} \sum_{t=1}^n |e_t|$$

şeklinde formülize edilmektedir ve önemli özellikleri aşağıda sunulmuştur.

- Bu hesaplama, öngörülen değerlerin orijinal değerlerden ortalama mutlak sapmasını ölçer.

- Tahmin nedeniyle meydana gelen toplam hatanın büyüklüğünü gösterir.
- MAE hataların yönü hakkında fikir vermez.
- İyi bir tahmin için, elde edilen MAE mümkün olduğunca küçük olmalıdır.
- MAE aşırı tahmin hatalarını panelize etmez (Adhikari ve Agrawal, 2013).


3.4.3. Zaman Serilerinde Kullanılan Algoritmalar

3.4.3.1. Uzun Kısa Süreli Bellek (LSTM)

Uzun Kısa Süreli Bellek (LSTM), tekrarlayan bir sinir ağıdır ve Sepp Hochreiter ve Jürgen Schmidhuber (1997) tarafından ortaya atılmış ve 2000 yılında Felix Gers ve arkadaşları tarafından geliştirilmiştir. Özellikle sınıflandırma problemleri ve zaman serisi tahmin problemleri gibi çeşitli alanlarda iyi sonuçlar vermektedir.

LSTM'ler, standart tekrarlayan sinir ağının uzun süreli bellek problemini çözmek için geliştirilmiştir ve tekrarlayan sinir ağları gibi zaman serisi verilerini işlerken farklı zamanlardaki verilerden de faydalanırlar. LSTM'nin standart tekrarlayan sinir ağından farkı, bünyesinde bulunan LSTM düğümlerinin farklı bir yapıdan meydana gelmesidir. LSTM'de, standart tekrarlayan sinir ağı hücresine hafıza hücresi eşlik etmektedir. Bu hafıza hücresinin sayesinde, bir önceki zamandan gelen veri alınarak bir sonraki zamana iletilebilmektedir. Model, hangi veriyi alıp almayacağına eğitim sayesinde karar verir. LSTM'ler de standart tekrarlayan sinir ağlarında olduğu gibi zincire benzeyen bir yapıdadırlar. Ancak, LSTM'lerde tek bir sinir katmanının yerine birbirleriyle etkileşime giren dört katman bulunmaktadır. Bu katmanlar Şekil 4'te gösterildiği gibidir.

Şekil 4: 4 Katmanlı LSTM Bloğu



Kaynak: Olah, 2015.

Yukarıdaki şekilde, her satır bir düğümün çıktısından diğerlerinin girişine kadar tüm vektörü taşımaktadır. Sarı kutularda sinir ağının katmanları öğrenilir, pembe daireler ise vektör eklenmesi gibi noktasal işlemleri temsil eder. Birleştirilen satırlar birleştirme hattını, çizgi çatallaştırma ise kopyalanan içeriğin ve kopyaların farklı yere gideceklerini belirtir.

3.4.3.2. Otoregresif Bütünleşik Hareketli Ortalama Modeli (ARIMA)

ARIMA modelleri, tek değişkenli tahmin görevlerinin yorumlanabilirliği ve doğruluğu açısından en popüler zaman serisi tekniklerindendir (Calster vd., 2017). ARIMA modelleri, ilk olarak Whittle (1954) tarafından ortaya çıkarılan ve daha sonra 1970'lerde Box ve Jenkins (Box vd., 2015) tarafından popüler hale getirilen ARIMA modelleri tarafından tahmin edilmektedir. Yöntemin en önemli varsayımlarından biri, uygulanan serinin eşit zaman aralıkları ile elde edilen gözlem değerlerinden oluşan kesikli ve durağan bir seri olmasıdır. Serinin durağan olmaması halinde ise, öncelikle bunun belirlenmesi ve serinin durağan hale getirilmesi gereklidir. Durağanlık, serinin periyodik dalgalanmalardan arınmış olması anlamına gelir. Bu sebeple, yöntemin uygulanabilmesi için trend bileşeni ya da mevsimsellik içeren seriler öncelikle durağanlaştırılmalıdır (Bircan ve Karagöz, 2003).

Bir ARIMA modeli, ARIMA (p, d, q) olarak tanımlanmaktadır.

p : Otoregresif modelin derecesi (AR)

d : Fark alma derecesi

q : Hareketli ortalama modelinin derecesi (MA)

∇ : Fark alma operatörü

w_t : Farkı alınmış seriyi ifade etmektedir.

$$x_t = \phi_1 w_{t-1} + \phi_2 w_{t-2} + \dots + \phi_p w_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

t zamanı için x_t gerçek veriyi, a_t hareketli ortalamadaki hatayı göstermektedir. Formüle bakılacak olursa; tahmin edilecek gerçek veri ile gözlemlenen q tane farkı alınmış veri ve q tane hata verisi arasında doğrusal bir ilişki kurulmuştur.

3.4.3.3. Facebook Prophet

Facebook Prophet, Facebook Temel Veri Bilim ekibi tarafından geliştirilmiş açık kaynak kodlu bir modeldir (Taylor ve Letham, 2018). Prophet, lineer olmayan eğilimlere sahip zaman serilerinin tahminlemelerini yapmaktadır. Model üzerinde kullanılacak veri setinde en az iki sütun bulunması gerekmektedir. Birinci sütunda “ds” yani zaman serileri gösterilir. İkinci sütunda ise “y” yani zaman serilerine karşılık gelen değerler gösterilir. Prophet modeli ile veri seti üzerindeki günlük, haftalık veya yıllık trend ve mevsimsellik analizi yapılabilir.

DÖRDÜNCÜ BÖLÜM

AĞ PERFORMANS RAPORLAMA SİSTEMİNİN TASARIMI VE UYGULAMASI

Sistem iki ayrı bölümden oluşmaktadır. Birinci bölüm, ağ trafiğini izler, kullanılan bant genişliğini kayıt altına alır, belirtilen eşik değerlerinin aşılması halinde loglar ve raporlar. İkinci bölüm ise birinci bölümde elde edilen trafik bilgilerinin makine öğrenmesi yöntemleriyle geleceğe yönelik tahminlenmesini yaparak kurum gereksinimleri hakkında bilgi edinilmesi sağlar.

4.1. UYGULAMA İLE İLGİLİ TANIMLAR

4.1.1. Bant Genişliği

Bant genişliği, kablolu veya kablosuz ağ bağlantısının, bir bilgisayar ağı veya internet bağlantısı üzerinden maksimum veri miktarını belirli bir sürede bir noktadan diğerine iletme kapasitesidir. Bant genişliği ne kadar büyük olursa belirli bir süre içinde aktarılabilecek veri hacmi de o kadar büyük olur. Bant genişliği, bir su borusundan akabilen su miktarı ile karşılaştırılabilir. Boru kalınlaştıkça, bir seferde akan su miktarı artar, boru inceldikçe bir seferde akan su azalır. Bu nedenle ağlarda bant genişliği önemlidir. Bant genişliğinin ölçü birimi bit per second (bps)'dir.

4.1.2. SNMP (Simple Network Management Protocol)

Ağ yöneticisine yardımcı olan basit bir uygulama katmanı protokolüdür. Temel anlamda, geniş ağlarda cihazların yönetimini ve denetimini kolaylaştırmak için tasarlanmıştır. SNMP kullanılarak ağda bulunan yönlendirici (router), anahtarlayıcı (switch), erişim sunucusu (access server), köprü (bridge) ve hatta bilgisayar gibi cihazların sıcaklığı, cihaza bağlı kullanıcıları, internet bağlantı hızı, cihaz çalışma süresi gibi temel bilgiler elde edilebilir. Bu şekilde ağın performansı artırılabilir, ağdaki problemler bulunup çözülebilir ya da ağda büyüme için önceden planlama yapılabilir.

4.1.3. MRTG (Multi Router Traffic Grapher)

Network üzerindeki trafiği SNMP protokolü vasıtasıyla izleyerek anlık olarak grafiksel içerikli HTML sayfaları oluşturan bir araçtır. MRTG, Perl ve C programlama dillerini kullanarak çalışır.

4.1.4. RRDTool

Ağ cihazlarına bağlı kullanıcı sayılarını ve bant genişliğini tespit etmede kullanılan açık kaynak kodlu yüksek performanslı veri kaydetme ve çizdirme aracıdır. RRD, Round Robin Veritabanı'nın kısaltmasıdır. RRD, zaman serisi verilerini (bant genişliği, makine odası sıcaklığı, sunucu yük ortalaması) depolayan ve görüntüleyen bir sistemdir. Verileri zaman içinde genişlemeyecek şekilde çok kompakt bir şekilde saklar ve belirli bir veri yoğunluğunu uygulamak için verileri işleyerek yararlı grafikler sunar.


4.1.5. Flask

Flask, web uygulamalarını geliştirmeyi sağlayan %100 Python ile yazılmış bir micro frameworktur. Küçük bir framework olmasına rağmen oldukça hızlıdır. Son derece esnektir. Öğrenilmesi ve kullanılması kolaydır. Bu sayede çok pratik ve kısa sürede uygulamalar yapılabilmektedir.

4.2. METODOLOJİ

Ağ Performans Raporlama Sistemi geliştirilirken her aşamada Sistem Geliştirme Yaşam Döngüsü adımları izlenmiştir. Sırasıyla problemler tanımlanmış, sistem gereksinimleri belirlenmiş, ihtiyaçlar analiz edilmiş, sistem tasarlanmış, yazılım geliştirilmiş, sistem test edilmiş ve son olarak sistem değerlendirilerek canlı ortama taşınmıştır.

Şekil 5: Sistem Geliştirme Yaşam Döngüsü



Kaynak: Tecim, 2015:3.

Problemin tanımlanması aşamasında, işletme faaliyetlerinin incelenmesi ve buna bağlı olarak problemlerin analiz edilmesi gerekmektedir.

Gereksinimlerin belirlenmesi aşamasında, karar vericilerin hangi bilgilere ihtiyaç duyduğu belirlenmiştir. Bu kapsamda; işletmeler için bant genişliği gereksinimi, geçmiş kullanımların değerlendirilmesine bağlıdır. Geçmişte ne kadarlık bir trafik yoğunluğunun olduğu ve zaman içerisinde ne gibi farklılıklar meydana geldiğinin belirlenmesi gerekmektedir.

İhtiyaçların analizi aşamasında, işletmenin ne tür verilerle hangi çıktıları elde etmek istediği analiz edilmiştir.

Sistem tasarımı aşamasında, uygulamanın ağ cihazlarından gerçek zamanlı olarak verileri toplayarak veri tabanına kaydetmesi ve raporlaması sağlanmıştır.

Yazılımın geliştirilmesi aşamasında, uygulamayı en etkin şekilde çalıştıracak programlama dilleri ve teknolojiler belirlenmiştir. Sistemin sade, anlaşılır ve fonksiyonel bir tasarıma sahip olması sağlanmıştır.

Sistemin test edilmesi aşamasında, uygulama canlı kullanıma verilmeden önce mümkün olduğunca gerçek verilerle ve gerçek kullanıcılarla test edilerek varsa hatalar tespit edilmeli ve giderilmeye çalışılmalıdır. Bu aşamada geliştirilen

uygulama test edilmiş ve canlı kullanıma verilmeden önce tespit edilen hatalar giderilmiştir.


Son aşama olarak sistemin gerçekleştirilmesi ve değerlendirilmesinde, sistemin tamamlanarak son kullanıcıya ulaştırılması hedeflenmiştir.

4.3. SİSTEM TASARIMI

4.3.1. Yöntem

Uygulama, geniş alan ağlarında bant genişliğinin en verimli şekilde kullanılabilmesinin sağlanması amacıyla geliştirilmiştir. Bu uygulama kapsamında 1 adet Cisco 3845 Router, 1 adet 3750 L3 Switch, 1 adet Web Server (Centos 6.9) ve 1 adet Veritabanı (MySQL) kullanılmıştır. Uygulamanın raporlama kısmı geliştirilirken php dili kullanılmış olup Cacti, MRTG ve RRDTool araçlarından faydalanılmıştır. Uygulamanın tahminleme kısmında ise makine öğrenmesi uygulamaları için oldukça popüler bir dil olan Python dili tercih edilmiştir. Web arayüzü için Python'ın web frameworkü Flask kullanılmıştır. Tahmin uygulaması geliştirilirken Python için birçok kütüphaneyi barındıran ve kullanım kolaylığı sağlayan Anaconda platformu ve içerdiği Jupyter Notebook kullanılmıştır. Veriyi görselleştirmek, işlemek ve matematiksel işlemler yapmak için Python kütüphaneleri olan Pandas, NumPy, Keras, Statsmodels, Matplotlib vb. sıkça yararlanılmıştır. Uygulamanın çalışma prensibi Şekil 6'daki gibidir.

Şekil 6: Uygulama Çalışma Prensibi



Kaynak: Yazar tarafından derlenmiştir.


Uygulamaya Router'ın adı, IP adresi, SNMP versiyonu, SNMP string ve SNMP port bilgileri girildikten sonra uygulama, ağ cihazına SNMP istekleri

göndermeye başlamaktadır ve uygulamanın ilgili bölümünde Router'ın arayüzleri listelenmektedir. Kullanıcı bu bölümde hakkında veri almak istediği arayüzü seçmektedir. Bu aşamadan sonra uygulama cihazın seçilen arayüzüne SNMP isteği gönderip bant genişliği verisini almaktadır. Uygulama aldığı veriyi veritabanına yazıp ve Grafikler kısmında kullanıcının anlayabileceği grafiğe dönüştürmektedir. Kullanıcı bu aşamadan sonra belirlediği bant genişliği değerinin aşılması durumunda uyarılması için uyarı ve/veya alarm eşik değerlerini girmesi gerekmektedir. Değerlerin girilmesinden sonra ikazlar aktif olacak ve eşik değerlerin aşılması durumunda uygulama Alarmlar kısmında bu aşımaları listeleyecektir. Bant genişliği değeri belirlenen sınırlar içerisine döndüğünde tekrar uygulama normale dönme uyarısında bulunacaktır. Tahmin kısmının kullanılabilmesi için Grafikler kısmında kullanıcı tarafından belirlenen tarih aralığına ait değerlerin export edilmesi ve Tahmin kısmına import edilmesi gerekmektedir.

4.3.2. Uygulama Arayüz Tasarımı

Uygulama tasarımı tamamen web tabanlı ve kullanıcı dostu olarak tasarlanmıştır.

Şekil 7: Uygulama Giriş Paneli




The image shows a user login interface titled "Kullanıcı Giriş Ekranı". It features a light gray rounded rectangle centered on a dark green background. Inside the rectangle, there are two input fields: "Kullanıcı Adı" (Username) and "Şifre" (Password). Below the password field is a checkbox labeled "Beni Hatırla" (Remember Me). At the bottom of the rectangle is a "Giriş" (Login) button.

Kaynak: Yazar tarafından derlenmiştir.

Şekil 7’de görüldüğü gibi uygulamada yetkisi bulunan kişiler, kullanıcı adı ve şifre bilgilerinin girerek dilerse beni hatırla seçeneğiyle sürekli şifre girişi yapmadan sisteme giriş yapabilmektedirler. Giriş yapıldıktan sonra kullanıcıyı Şekil 8’deki gibi konsol arayüzü karşılamaktadır.

Şekil 8: Uygulama Genel Görünümü



Kaynak: Yazar tarafından derlenmiştir.

Uygulamanın ana sayfasında; kullanıcılar, kısayol linklerini kullanarak uygulamaya cihaz oluşturulabilmekte, oluşturulan cihazların seçilen arayüzüne ait bant genişliği değerlerinin takip edilebilmesi için grafikler oluşturulabilmekte ve oluşturulan grafikler izlenebilmektedir.

Şekil 9’da cihaz oluşturma paneli görülmektedir. Cihaz ekleyebilmek için; cihaza anlamlı bir isim, cihazın IP adresi, cihaz üzerinde tanımlı SNMP versiyonu, SNMP iletişim stringi ve SNMP portunun girilmesi gerekmektedir. Ayrıca cihazın kapalı mı açık mı olduğunu tespit edebilmek amacıyla SNMP Uptime veya Ping seçeneklerinden biri seçilmelidir. Akıllı cihazlarda kapalı cihaz tespitinin ağa ekstra yük getirmeyeceğinden dolayı SNMP Uptime ile yapılması yerinde olacaktır. Bu değerler girildikten sonra cihaz uygulamaya eklenecektir. Ancak yukarıda belirtilen

değerlerden bir tanesinin bile yanlış veya eksik girilmesi uygulamanın cihaza erişememesine neden olacaktır.

Şekil 9: Cihaz Oluşturma Paneli

Kaynak: Yazar tarafından derlenmiştir.

Şekil 10'da başarılı bir şekilde eklenmiş cihazların liste bulunmaktadır. Eklenen cihazın Grafikler kısmında görünebilmesi için, eylemlerden geniş alan ağlarından birine eklenmesi gerekmektedir.

Şekil 10: Cihaz Listeleme Paneli

Kaynak: Yazar tarafından derlenmiştir.

Şekil 11’de cihazın bant genişliğinin takip edilmesi istenen arayüzüne grafik oluşturma paneli bulunmaktadır. Panelde izlenmesi istenen arayüz veya arayüzlerin seçimi yapılmasının ardından grafik türü In/Out Bits veya In/Out Bytes seçilmelidir. Genel kullanım bps (bits per second) değeri üzerinden olduğundan In/Out Bits seçilmesi daha doğru olacaktır.

Şekil 11: Grafik Oluşturma Paneli

The screenshot shows the 'Yeni Grafik Oluşturma' (New Graph Creation) panel. The left sidebar contains navigation links: Giriş, Grafikler, Alarmlar, Tahmin, and a sub-menu for 'Yeni Grafik Oluşturma'. The main area is titled 'Yeni Grafik Oluşturma [Test (192.168.1.1)]'. It includes a search bar with 'Cihaz' set to 'Test' and 'Grafik Türleri' set to 'Tümü'. Below this is a table of network interfaces. The interface 'eth1.35' is highlighted. At the bottom, there is a 'Grafik Türü Seçiniz' dropdown menu set to 'Varsayılan Ayarla' and a button 'Oluştur'.


S/N	Durum	Arayüz Adı	Tür	Hız	MAC Adresi	IP Address
2	Down	ifb0	6	100000000	D6:B2:C3:32:D2:12	127.0.0.1
17	Up	eth1.35	6	100000000	D4:6E:0E:A6:13:FA	192.168.1.1
21	Down	ppp0	23	0		88.226.213.73

Kaynak: Yazar tarafından derlenmiştir.

Şekil 12’deki grafik izleme panelinde, cihaz için oluşturulmuş grafiklerden birinin örneği bulunmaktadır. Bu ekranda WAN-1’de ekli olan “Test” cihazı için grafik filtreleri kullanılmış ancak tek grafik oluşturulduğundan sadece 1 adet grafik görüntülenmiştir. Grafik filtrelerinde, ön ayarlar kısmında tanımlanmış zaman parametreleri bulunmaktadır. Ancak kullanıcı isterse zaman aralığını, başlangıç ve bitiş tarih saat aralığından kendisi belirleyebilir ve istediği zaman aralığına ait grafiği veya grafikleri görüntüleyebilir. Şekil 12’de örnek olarak 28 Aralık 2016 tarihi ile 22 Haziran 2017 tarihleri arasındaki bant genişliği kullanım grafiği görüntülenmiştir. Grafiğin alt kısmında gelen verilerin anlık, ortalama ve maksimum değerleri

görülmektedir. Buna göre bu tarihler arasındaki maksimum gelen trafik değeri 29.91 Mbps ve ortalama gelen trafik değeri 19.25 Mbps olmuştur.


Şekil 12: Grafik İzleme Paneli



Kaynak: Yazar tarafından derlenmiştir.

Şekil 13'teki grafik ortalamaları panelinde test cihazının, değerlerin bakıldığı tarihin geçmişine doğru saatlik, günlük, haftalık, aylık ve yıllık ortalama değerleri görülmektedir.


Şekil 13: Grafik Ortalamaları



Kaynak: Yazar tarafından derlenmiştir.

Şekil 14’te grafiklerin eşik değerlerini takip etmemizi kolaylaştıran alarm oluşturma sihirbazı görülmektedir.

Şekil 14: Grafiğe Alarm Eşik Değerlerinin Eklenmesi



Kaynak: Yazar tarafından derlenmiştir.

Şekil 15’te oluşturulan alarmın ayarları görülmektedir. Bu bölümde uyarı ve alarmların alt ve üst limitleri belirlenebilmektedir. Uyarı ve alarm değerleri aktif edildiğinde uyarı eşik değeri aşıldığında konsolda öncelikle uyarı aktif olacak, daha sonra alarm eşik değeri de aşıldığında alarm aktif olacaktır.


Şekil 15: Grafiğe Eklenen Alarm Ayarlarının Yapılması

Genel Ayarlar	
Alarm Adı	Test - Traffic - 88.226.213.73/ppp0 [traffic_in]
Alarm Aktif	☐ Alarm Aktif
Haftasonu Pasif	☐ Haftasonu Pasif
Uyarı Rengi	Earth Blue (0000A0) ▼
Alarm Rengi	Firebrick (800517) ▼
Alarm Türü	Yüksek / Düşük ▼
Alarm Döngüsü	Hiç ▼
Uyarı - Tavan / Taban Ayarları	
Üst Limit	
Alt Limit	
Alarm - Tavan / Taban Ayarları	
Üst Limit	
Alt Limit	
Veri İşleme	
Veri Türü	Tam Değer ▼
Geri Dön Kaydet	

Kaynak: Yazar tarafından derlenmiştir.

Şekil 16’da alarm ve uyarı değerleri eklendikten sonra grafiğin görünüşü bulunmaktadır. Şekil 15’te Alarm rengi için kırmızı ve uyarı rengi mavi tercih edildiği için Şekil 16’da bu renkli sınır çizgileri yatay olarak görünmektedir.

Şekil 16: Alarm Değerleri Eklenmiş Grafik Görünümü



Kaynak: Yazar tarafından derlenmiştir.

Şekil 17’de alarm durumlarının takip edildiği konsol görülmektedir. Bu bölümde cihazlar belirlenen değer aralığına göre renklendirilmektedir. Örnek olarak biri normal değerler aralığında olan diğeri ise pasif edilmiş iki cihaz verilmiştir.

Şekil 17: Alarm Konsol Ekranı

Giriş

Grafikler

Alarmlar

Tahmin

Konsol

admin kullanıcısı ile giriş yapıldı

Konsol

Loglar

Cihaz Durumları

Alarm Durumları

Arama

Bir arama terimi girin

Q

Cihaz

Hepsi

Git

Temizle

Şablon

Hepsi

Durum

Hepsi

Satır

Varsayılan

Eylemler	İsim	Anlık Değer	Uyan Tavan/Taban Değeri	Alarm Tavan/Taban Değeri	Tetik	Tekrar	Tetiklendi mi?
	Test - Traffic - 78.168.16.68/ppp0 [traffic_in]	54.8	12,000,000/-	28,000,000/-	1 Seçim	Her 3 Seçim	Hayır
	Wifi - Traffic - 78.168.16.68/ppp0 [traffic_in]	54.8	2,000,000/-	3,000,000/-	1 Seçim	Her 3 Seçim	Hayır
Alarm	Uyarı	Normal Değer Geçilmiş	Normal				Pasif

Kaynak: Yazar tarafından derlenmiştir.

Şekil 18’de alarmlara ait logların izlendiği bölüm görülmektedir. Bu alanda; loglar alarmlar, uyarılar ve devam eden uyarılar olarak 3’e ayrılmaktadır. Alarmlar kırmızı renkte, Uyarılar koyu turuncu ve Devam eden uyarılar açık turuncu renkte gösterilmektedir. Loglarda cihaz adı, zaman, ölçülen değer, ikaz değeri ve olay açıklaması bulunmaktadır.

Şekil 18: Alarm Logları

Giriş

Grafikler

Alarmlar

Tahmin

Alarm Logları

admin kullanıcısı ile giriş yapıldı

Konsol

Loglar

Cihaz Durumları

Alarm Logları [Süresiz]

Arama

Bir arama terimi girin

Q

Git

Temizle

Cihazlar

Test - Traffic - 78.168.16.68/ppp0 [traffic_in]

Durum

Hepsi

Satır Sayısı

Varsayılan

19 Log

Cihaz	Zaman	Ölçülen Değer	Uyarı Değeri	Olay Açıklaması
Test	05-03-2020 01:06:25	10,311	-	NORMAL: Test - Traffic - 78.168.16.68/ppp0 [traffic_in]10310.7778 bps değeri ile bant genişliği normal değerlerdedir.
Test	05-03-2020 01:06:15	3,371,162	3,000,000	ALARM: Test - Traffic - 78.168.16.68/ppp0 [traffic_in]3371162 bps ile ALARM sınırının üzerine çıktı!
Test	05-03-2020 00:58:03	158	-	NORMAL: Test - Traffic - 78.168.16.68/ppp0 [traffic_in]157.8182 bps değeri ile bant genişliği normal değerlerdedir.
Test	05-03-2020 00:57:52	2,695,601	2,000,000	UYARI: Test - Traffic - 78.168.16.68/ppp0 [traffic_in]2695601.1 bps ile UYARI sınırının üzerine çıktı!
Test	05-03-2020 00:39:53	125,162	-	NORMAL: Test - Traffic - 78.168.16.68/ppp0 [traffic_in]125162.3 bps değeri ile bant genişliği normal değerlerdedir.
Test	05-03-2020 00:39:43	428,115,221	3,000,000	ALARM: Test - Traffic - 78.168.16.68/ppp0 [traffic_in]428115221.1 bps ile ALARM sınırının üzerine çıktı!
Test	04-03-2020 19:59:02	1,144,361	-	NORMAL: Test - Traffic - 78.168.16.68/ppp0 [traffic_in]1144361.3 bps değeri ile bant genişliği normal değerlerdedir.
Test	04-03-2020 19:58:52	2,845,381	2,000,000	UYARI: Test - Traffic - 78.168.16.68/ppp0 [traffic_in]2845381.2 bps ile UYARI sınırının üzerine çıktı!
Test	04-03-2020 19:58:42	62	-	NORMAL: Test - Traffic - 78.168.16.68/ppp0 [traffic_in]61.6 bps değeri ile bant genişliği normal değerlerdedir.
Test	04-03-2020 19:58:13	2,252,676	2,000,000	UYARI: Test - Traffic - 78.168.16.68/ppp0 [traffic_in]2252676.4 bps ile UYARI sınırının üzerine çıktı!
Test	04-03-2020 19:58:03	1,486,420	-	NORMAL: Test - Traffic - 78.168.16.68/ppp0 [traffic_in]1486419.5455 bps değeri ile bant genişliği normal değerlerdedir.
Test	04-03-2020 19:57:52	4,055,868	3,000,000	ALARM: Test - Traffic - 78.168.16.68/ppp0 [traffic_in]4055867.6 bps ile ALARM sınırının üzerine çıktı!
Test	04-03-2020 19:28:02	1,267,969	-	NORMAL: Test - Traffic - 78.168.16.68/ppp0 [traffic_in]1267968.8 bps değeri ile bant genişliği normal değerlerdedir.
Test	04-03-2020 19:27:57	3,417,118	3,000,000	ALARM: Test - Traffic - 78.168.16.68/ppp0 [traffic_in]3417118.4 bps ile ALARM sınırının üzerine çıktı!
Test	04-03-2020 19:21:42	280,796	-	NORMAL: Test - Traffic - 78.168.16.68/ppp0 [traffic_in]280796.2222 bps değeri ile bant genişliği normal değerlerdedir.
Test	04-03-2020 19:20:13	3,892,010	3,000,000	ALARM: Test - Traffic - 78.168.16.68/ppp0 [traffic_in]3892010.2 bps ile ALARM sınırının üzerine çıktı!
Test	04-03-2020 13:33:13	1,952,809	-	NORMAL: Test - Traffic - 78.168.16.68/ppp0 [traffic_in]1952809 bps değeri ile bant genişliği normal değerlerdedir.
Test	04-03-2020 13:32:52	4,251,449	3,000,000	ALARM: Test - Traffic - 78.168.16.68/ppp0 [traffic_in]4251449.3 bps ile ALARM sınırının üzerine çıktı!
Test	04-03-2020 13:32:42	2,492,980	2,000,000	UYARI: Test - Traffic - 78.168.16.68/ppp0 [traffic_in]2492980.2 bps ile UYARI sınırının üzerine çıktı!

19 Log

Alarmlar

Uyarılar


Devam Eden Uyarılar

Normal

Kaynak: Yazar tarafından derlenmiştir.

Şekil 19’da alarm eklenen cihazlara ait durum faaliyet durumu görülmektedir. Kırmızı renk cihaza ulaşamadığını, turuncu cihazın açılmakta olduğunu, yeşil ulaşılabilir olduğunu, mavi cihazın ilk defa sisteme eklendiği sırada ulaşamadığını ve gri ise cihazın pasif edildiğini belirtmektedir. Örnek olarak cihazın ulaşılabilir olduğu durum gösterilmiştir.

Şekil 19: Cihaz Durumları



Eylemler	Cihaz Adı	Grafikler	Durum	Çalışma Süresi	Cihaz IP	Anlık (ms)	Ortalama (ms)	Ulaşılabilirlik
Wifi	1		Açık	1d:17h:35m	192.168.1.1	5.14	7.7	%99.43
Ulaşamaz			Açılıyor					Pasif

Kaynak: Yazar tarafından derlenmiştir.

Şekil 20’de uygulamanın tahmin sayfası görülmektedir. Tahmin uygulaması ARMA modellerini kullanarak tahminler yapmaktadır. Bunun sebebi tartışma bölümünde ayrıntılarıyla anlatılacaktır.

Şekil 20: Tahmin Sayfası Veri Giriş Ekranı



Tahmin Sayfası

Dosya seçilmedi

☐ 1 Aylık
☐ 3 Aylık
☐ 6 Aylık

Kaynak: Yazar tarafından derlenmiştir.

Uygulamanın raporlama kısmından export edilen csv dosyası sisteme yüklenerek geleceğe yönelik 1, 3 ve 6 aylık tahminler yapabilmektedir. Burada bir nevi otomatikleştirilmiş makine öğrenme sistemi kurulmuştur. Sistem, girilen her veri setinin tahminlerini back-end kısmında pm.auto_arima ile en uygun ARMA modelini seçerek yapmaktadır. Pm.auto_arima ile ilgili kod parçasığı Şekil 21’de gösterilmiştir.

Şekil 21: Örnek Kod Parçasığı


```
model = pm.auto_arima(data.values, start_p=1, start_q=1,
                      test='adf',
                      max_p=5, max_q=5,
                      m=1,
                      d=None,
                      seasonal=False,
                      start_P=0,
                      D=0,
                      trace=True,
                      error_action='ignore',
                      suppress_warnings=True,
                      stepwise=True)

print(model.summary())
```

Kaynak: Yazar tarafından derlenmiştir.

Şekil 20’deki arayüzden girilen örnek veri setinin back-end’de pm.auto_arima ile bulunan en uygun model ARMA(2,4)’e göre tahmin grafiği sonucu Şekil 22’de gösterilmiştir.

Şekil 22: Tahmin Sonucu




Kaynak: Yazar tarafından derlenmiştir.

4.4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

4.4.1. Raporlama

Uygulamanın raporlama kısmı ile “Ne oldu?” ve “Niçin oldu?” sorularına cevaplar bulunmaya çalışılmıştır.


Şekil 23: 6 Aylık Bant Genişliği Kullanımı



Kaynak: Yazar tarafından derlenmiştir.

22 Aralık 2016 ile 22 Haziran 2017 tarihleri arasında kurumun 6 aylık internet bant genişliği kullanım grafiği Şekil 23'te sunulmuştur. Buna göre 22 Haziran 2017 tarihinde saat 12:03:55'te anlık kullanımın 24,71 Mbps olduğu, 6 aylık sürede ortalama kullanımın 19,25 Mbps ve maksimum kullanımın 29,91 Mbps olduğu görülmektedir.


Şekil 24: Ocak Ayı Bant Genişliği Kullanımı



Kaynak: Yazar tarafından derlenmiştir.

Şekil 24'te Ocak ayı internet bant genişliği kullanımının ortalama 14,75 Mbps olduğu görülmektedir. Ocak ayının ilk iki haftasında kurumda eğitilen öğrencilerin ara tatilde olması nedeniyle internet kullanımı azalmıştır.


Şekil 25: Şubat-Mart-Nisan Ayları Bant Genişliği Kullanımı



Kaynak: Yazar tarafından derlenmiştir.

Şekil 25'te Şubat-Mart-Nisan ayları internet bant genişliği kullanımının ortalama 19,71 Mbps olduğu görülmektedir. Bu 3 ayda öğrenci kullanımının artması nedeniyle ocak ayına göre yükselme görülmüştür.

Şekil 26: Mayıs-Haziran Ayları Bant Genişliği Kullanımı




Kaynak: Yazar tarafından derlenmiştir.

Şekil 26'da Mayıs ve Haziran ayları internet bant genişliği kullanımının ortalama 13,19 Mbps olduğu görülmektedir.

Mayıs ve Haziran ayları öğrencilerden büyük bir kısmının diğer kurumlarda uygulamalı branş eğitimi aldıkları aylar olduğundan dolayı bant genişliği kullanımı önceki aylara göre yarı yarıya düştüğü görülmüştür.

Şekil 27’de her iki gün de saat 00:00’dan sonra internet kullanımının neredeyse durduğu görülmektedir. Bu kapsamda, kuruma ait sistem odası ve sunucu bakımlarının 00:00 ile 06:00 saatleri arasında yapılmasının uygun olacağı değerlendirilmektedir.


Şekil 27: 2 Günlük Gece Bant Genişliği Kullanım Durumu



Kaynak: Yazar tarafından derlenmiştir.

Şekil 28’de ortalama değer 10,60 Mbps iken maksimum trafik değerinin 50 Mbps üzerine çıktığı görülmektedir. Bunun sebebi ise 12 Ocak, 28 Şubat ve 19 Nisan 2017 tarihlerinde öğrenci ve personel seçim sınav sonuçlarının açıklanmasıdır. Bu tarihler dışında ortalama giden trafik değeri yaklaşık 5 Mbps civarındadır.

Şekil 28: 6 Aylık Kurum Dışına Giden Trafik Durumu




Kaynak: Yazar tarafından derlenmiştir.

4.4.2. Tahminleme

Bu bölümde, makine öğrenmesi modellerinden Prophet, LSTM ve ARMA modellerinin eğitilmesinde öğrenci yetiştiren bir kurumun 6 aylık bant genişliği verileri kullanılmıştır. Modeller eğitilirken, verilerin azlığı nedeniyle verilerin tamamı eğitim için kullanılarak testler yapılmıştır. Sırasıyla Prophet, LSTM ve ARMA modelleri eğitilmiş ve tahmin sonuçlarına göre MAE, MSE ve RMSE değerleri hesaplanmış ve en uygun model seçilerek uygulamanın tahmin kısmında kullanılmıştır.

Şekil 29’da prophet modelinin eğitilmesi sonucunda ortaya çıkan tahmin grafiği gösterilmiştir.

Şekil 29: Prophet Modeli Tahmin Grafiği



Kaynak: Yazar tarafından derlenmiştir.

Prophet modelinin MAE, MSE ve RMSE değerleri Tablo-2’de son 30 günlük tahmin değerleri de Tablo-3’te sunulmuştur.

Tablo 2: Prophet Modeli Metrik Hesaplamaları

Prophet	MAE	MSE	RMSE
	1.330854	3.308479	1.818923

Kaynak: Yazar tarafından derlenmiştir.

Tablo 3: Prophet Modeli Tahmin Değerleri

Tarih	Inbound	Prophet Tahmini
2017-05-17	8.540941	7.875356
2017-05-18	6.444382	7.084820
2017-05-19	6.571916	7.523662
2017-05-20	6.063835	6.734995
2017-05-21	4.127398	4.875563
2017-05-22	4.037085	4.236896
2017-05-23	8.499341	6.906253
2017-05-24	11.522150	8.015725
2017-05-25	10.589190	7.225188
2017-05-26	12.574770	7.664030
2017-05-27	8.728158	6.875363
2017-05-28	4.795639	5.015932
2017-05-29	3.146494	4.377264
2017-05-30	7.308730	7.046621
2017-05-31	9.756093	8.156093
2017-06-01	9.475067	7.365557
2017-06-02	8.210147	7.804399
2017-06-03	8.515114	7.015732
2017-06-04	3.939652	5.156301
2017-06-05	1.911343	4.517633
2017-06-06	9.371939	7.186990
2017-06-07	9.830126	8.296462
2017-06-08	6.630480	7.505926
2017-06-09	9.190963	7.944768
2017-06-10	7.109757	7.156101
2017-06-11	3.162117	5.296669
2017-06-12	3.716105	4.658002
2017-06-13	7.190160	7.327359
2017-06-14	9.035223	8.436831
2017-06-15	7.656462	7.646294

Kaynak: Yazar tarafından derlenmiştir.

LSTM modeli eğitilirken ilk 3 değer verilerek 4. değerin tahmin edilmesi sağlanmıştır. Tek katmanlı bir yapıda 200 LSTM nöronu, aktivasyon fonksiyonu olarak “Relu”, optimizasyon algoritması olarak “Adam” ve epoch yani geri besleme işlem adedi olarak da 300 kullanılmıştır. İlgili kod parçacığı Şekil 30’da gösterilmiştir.

Şekil 30: LSTM Modeli Kod Parçacığı

```
model = Sequential()
model.add(LSTM(200, activation='relu', input_shape=(n_steps, n_features)))
model.add(Dropout(0.5))
model.add(Dense(1))
model.compile(optimizer='adam', loss='mse')


model.fit(X, y, epochs=300, verbose=0)

predictions = []
for i in range(len(X)):
    x_input = X[i]
    x_input = x_input.reshape((1, n_steps, n_features))
    yhat = model.predict(x_input, verbose=0)
    predictions.append(yhat[0][0])
```

Kaynak: Yazar tarafından derlenmiştir.

Şekil 31’de LSTM modelinin eğitilmesi sonucunda ortaya çıkan tahmin grafiği gösterilmiştir.

Şekil 31: LSTM Modeli Tahmin Grafiği



Kaynak: Yazar tarafından derlenmiştir.

LSTM modelinin MAE, MSE ve RMSE deęerleri Tablo-4’de son 30 gnlk tahmin deęerleri de Tablo-5’te sunulmuřtur.

Tablo 4: LSTM Modeli Metrik Hesaplamaları

LSTM	MAE	MSE	RMSE
	1.692504	4.563651	2.136270

Kaynak: Yazar tarafından derlenmiřtir.

Tablo 5: LSTM Modeli Tahmin Deęerleri

Tarih	Inbound	LSTM Tahmini
2017-05-17	8.540941	5.696608
2017-05-18	6.444382	7.245281
2017-05-19	6.571916	5.393818
2017-05-20	6.063835	6.468335
2017-05-21	4.127398	5.004786
2017-05-22	4.037085	4.067089
2017-05-23	8.499341	4.392187
2017-05-24	11.522150	6.069258
2017-05-25	10.589190	9.267422
2017-05-26	12.574770	8.675153
2017-05-27	8.728158	10.841709
2017-05-28	4.795639	7.460255
2017-05-29	3.146494	7.077316
2017-05-30	7.308730	5.215551
2017-05-31	9.756093	5.964700
2017-06-01	9.475067	7.836557
2017-06-02	8.210147	7.652391
2017-06-03	8.515114	7.098973
2017-06-04	3.939652	7.463826
2017-06-05	1.911343	4.369673
2017-06-06	9.371939	4.507860
2017-06-07	9.830126	7.005127
2017-06-08	6.630480	8.896119
2017-06-09	9.190963	6.098875
2017-06-10	7.109757	9.147089
2017-06-11	3.162117	6.151187
2017-06-12	3.716105	4.807536
2017-06-13	7.190160	5.187221
2017-06-14	9.035223	5.008721
2017-06-15	7.656462	7.478560

Kaynak: Yazar tarafından derlenmiřtir.

ARIMA(p,d,q) modeli eğitilmeden önce zaman serisinde durağanlık kontrolünün yapılması gerekmektedir. Elimizde bulunan veri setine durağanlık testi uygulanmış ve Şekil 32’de görüldüğü üzere p değeri 0.05’ten büyük olduğu için fark alma işlemi uygulanarak serinin durağanlaştırılması sağlanmıştır. Böylelikle d=1 olmuştur.


Şekil 32: Durağanlık Test Sonuçları

Farkı Alınmadan Önce Seri	Farkı Alındıktan Sonra Seri
ADF Statistic: -2.545364	ADF Statistic: -4.295399
p-value: 0.104823	p-value: 0.000452
Critical Values:	Critical Values:
1%: -3.472	1%: -3.474
5%: -2.880	5%: -2.881
10%: -2.577	10%: -2.577

Kaynak: Yazar tarafından derlenmiştir.

Modele ilişkin otokorelasyon (ACF) ve kısmi otokorelasyon (PACF) grafikleri çizdirilerek p ve q parametreleri hakkında öngörü sağlanmıştır (Şekil 33).

Şekil 33: ACF ve PACF Grafikleri



Kaynak: Yazar tarafından derlenmiştir.

Modelin seçimi ve yeterliliğinin test edilmesi amacıyla auto_arima fonksiyonu kullanılarak en küçük AIC (Akaike Bilgi Ölçütü) ve BIC (Bayesci Bilgi Ölçütü) değerlerinin tespit edilmesi sağlanmıştır (Şekil 34). Auto ARIMA sonucunda en düşük AIC: 5228.391 ve BIC: 5253.239 değerleriyle modelin ARMA(2,4) olduğu görülmüştür.

Şekil 34: Auto ARIMA Sonucu

SARIMAX Results

Dep. Variable: y

No. Observations: 166

Model: SARIMAX(2, 1, 4)

Log Likelihood -2606.196

Date: Fri, 15 May 2020

AIC 5228.391

Time: 00:21:55

BIC 5253.239

Sample: 0

HQIC 5238.478

- 166


Covariance Type: opg

	coef	std err	z	P> z	[0.025	0.975]
intercept	6.872e+04	3.46e+04	1.986	0.047	913.015	1.37e+05
ar.L1	1.2337	0.029	42.897	0.000	1.177	1.290
ar.L2	-0.9880	0.031	-31.481	0.000	-1.050	-0.926
ma.L1	-1.5914	0.088	-18.079	0.000	-1.764	-1.419
ma.L2	0.9971	0.163	6.125	0.000	0.678	1.316
ma.L3	0.1209	0.158	0.766	0.444	-0.188	0.430
ma.L4	-0.3263	0.092	-3.559	0.000	-0.506	-0.147
sigma2	3.656e+12	8.54e-05	4.28e+16	0.000	3.66e+12	3.66e+12

Kaynak: Yazar tarafından derlenmiştir.

En uygun ARMA(2,4) modelinin kalıntılarına ilişkin elde edilen göstergeler Şekil 35'te verilmiştir.


Şekil 35: ARMA Modeli Göstergeleri



Kaynak: Yazar tarafından derlenmiştir.

Şekil 36’da ARMA modelinin eğitilmesi sonucunda ortaya çıkan tahmin grafiği gösterilmiştir.

Şekil 36: ARMA Modeli Tahmin Grafiği



Kaynak: Yazar tarafından derlenmiştir.

ARMA modelinin MAE, MSE ve RMSE değerleri Tablo-6’da son 30 günlük tahmin değerleri de Tablo-7’de sunulmuştur.

Tablo 6: ARMA Modeli Metrik Hesaplamaları

ARMA	MAE	MSE	RMSE
	1.295983	2.846368	1.687118

Kaynak: Yazar tarafından derlenmiştir.


Tablo 7: ARMA Modeli Tahmin Değerleri

Tarih	Inbound	ARMA Tahmini
2017-05-17	8.540941	8.811629
2017-05-18	6.444382	7.371608
2017-05-19	6.571916	5.594896
2017-05-20	6.063835	4.963921
2017-05-21	4.127398	4.478681
2017-05-22	4.037085	4.453015
2017-05-23	8.499341	5.991936
2017-05-24	11.522150	9.126014
2017-05-25	10.589190	9.525817
2017-05-26	12.574770	7.676211
2017-05-27	8.728158	8.417249
2017-05-28	4.795639	5.674853
2017-05-29	3.146494	5.865948
2017-05-30	7.308730	6.760640
2017-05-31	9.756093	10.234700
2017-06-01	9.475067	9.944727
2017-06-02	8.210147	8.159476
2017-06-03	8.515114	6.116678
2017-06-04	3.939652	6.407642
2017-06-05	1.911343	4.650878
2017-06-06	9.371939	6.328191
2017-06-07	9.830126	11.588400
2017-06-08	6.630480	9.504168
2017-06-09	9.190963	6.725498
2017-06-10	7.109757	7.186848
2017-06-11	3.162117	4.869589
2017-06-12	3.716105	4.583846
2017-06-13	7.190160	7.084026
2017-06-14	9.035223	9.687372
2017-06-15	7.656462	9.606248

Kaynak: Yazar tarafından derlenmiştir.

Şekil 37’de ARMA, LSTM ve Prophet modellerinin eğitilmesi sonucunda ortaya çıkan karşılaştırma grafiği gösterilmiştir.

Şekil 37: Model Karşılaştırma Grafiği



Kaynak: Yazar tarafından derlenmiştir.

Prophet, LSTM ve ARMA modellerinin performans değerleri Tablo 8’de karşılaştırılmıştır.


Tablo 8: ARMA, LSTM ve Prophet Modelleri Performans Karşılaştırması

	ARMA	LSTM	Prophet
MAE	1.295983	1.673437	1.330854
MSE	2.846368	4.581741	3.308479
RMSE	1.687118	2.140500	1.818923

Kaynak: Yazar tarafından derlenmiştir.

Bu değerlere bakıldığında performansı en iyi olan modelin MAE, MSE ve RMSE değerlerinin sıfıra en yakın olan ARMA olduğu görülmektedir. Bu yüzden uygulamanın tahmin kısmında ARMA modelleri kullanılmıştır. Şekil 38’de ARMA(2,4) modelinin ürettiği 30 günlük tahmin görülmektedir.

Şekil 38: 30 Günlük Tahmin Grafiği



Kaynak: Yazar tarafından derlenmiştir.

SONUÇ

Günümüz teknolojisinde internet tabanlı uygulamaların sayısı hızla artmaktadır. Gelecekte günlük yaşantımızda kullandığımız her şeyin de internete bağlanacağını düşünürsek büyük şirketlerin, üniversitelerin, askeri kurumların vb. kullandığı geniş alan ağlarının yetmeyeceği aşikârdır. Ağlardaki bu yoğunluk verilerin akışı için ağ trafiğinde ciddi performans sorunlarına neden olacaktır. Geniş alan ağlarına sahip bu tür kurumların kaynaklarını maliyeti artırmadan verimli ve orantılı bir şekilde kullanması gerekmektedir. Bu yüzden kurumlar, geçmiş kullarımlarını çok iyi analiz etmelidir. Aynı zamanda geçmiş verilere bakarak gelecek kullarımlarının da öngörülmesi gerekmektedir ki kısa ve orta vadeli plan yapılabilirsin.

Çalışma kapsamında toplam bant genişliği 30 Mbps olan öğrenci ve personel yetiştiren bir kurumun 6 aylık bant genişliği verileri kullanılmıştır. 6 aylık sürede ortalama kullanımın 19,25 Mbps ve maksimum kullanımın 29,91 Mbps olduğu tespit edilmiştir. Öğrencilerin kurumda bulunmadığı Ocak, Mayıs ve Haziran aylarında ağ kullanımının kurumda bulundukları Şubat, Mart ve Nisan aylarına göre daha az olduğu görülmüştür. Ağ kullanımı Ocak ayında ortalama 14,75 Mbps, Mayıs ve Haziran aylarında ortalama 13,19 Mbps iken, Şubat, Mart ve Nisan aylarında 19,71 Mbps olarak gözlemlenmiştir. 6 aylık sürede kurum dışına giden trafiğin 10,60 Mbps olduğu, ancak bazı günlerde 50 Mbps değerine ulaştığı ve bugünlerde öğrenci ve personel seçim sonuçlarının açıklandığı görülmüştür.

Uygulamadan elde edilen veri setine geleceğe yönelik tahminde bulunabilmek için zaman serisi analizi uygulanmıştır. Literatürde bant genişliği verisi için en çok kullanılan makine öğrenme algoritmalarından ARMA ve LSTM kullanılmıştır. Bunun yanında Facebook tarafından geliştirilen Prophet algoritması da değerlendirmeye alınmıştır. Modellere uygulanan algoritmaların tahmin doğruluğu performans değerlendirme ölçütü olarak MAE, MSE ve RMSE metrik ölçümleri kullanılmıştır. Veri setine uygulanan algoritmalarından MAE: 1.295983, MSE: 2.846368 ve RMSE: 1.687118 değerleriyle en başarılı sonucu veren algoritma, ARMA algoritması olmuştur.

Bu anlamda, çalışma kapsamında geliştirilen uygulama ile;

- Bant genişliği yönetimine katkı sağlayan ağ performansı izlenebilmektedir.
- İzlenen ağda oluşan bir yoğunluğun ne zaman, ne miktarda ve ne kadar sürdüğü tespit edilebilmektedir.
- Ağlar da oluşabilecek anomaliler tespit edilebilmektedir.
- Günlük, haftalık, aylık ve yıllık kullanımlar raporlanabilmektedir.
- Geçmiş kullanımlara bakılarak belirtilen sürede makine öğrenmesi algoritmaları kullanılarak geleceğe yönelik öngörude bulunulabilmektedir.

Yönetim Bilişim Sistemleri, organizasyondaki bütün verileri toplayarak bunlardan yöneticiye anlaşılır bilgiler aktarmaya yarayan sistemlerdir. Yöneticinin verecek olduğu bir kararda, ihtiyacı olan bilgilere hızlı bir şekilde ulaşmasını sağlamaktadır. Bu anlamda bakıldığında ağ performans raporlama sistemi yöneticilere karar vermesinde yardımcı olan bir karar destek sistemi olarak değerlendirilmektedir.

KAYNAKÇA

Acito, F., Khatri, V. (2014). Business Analytics: Why Now and What Next?, Business Horizons, Cilt 57, Sayı 5, 565-570.

Adhikari, R. ve Agrawal, R. (2013). An Introductory Study on Time series Modeling and Forecasting. 10.13140/2.1.2771.8084.

Alpaydin, E. (2014). Introduction to Machine Learning. Massachusetts: MIT press.

Azvine, B., Cui, Z. ve Nauck, D.D. (2005) Towards real-time business intelligence. BT Technol J 23, 214–225.

Banerjee, A., Bandyopadhyay, T. ve Acharya, P. (2013). Data analytics: Hyped up aspirations or true potential. Vikalpa: The Journal for Decision Makers, 38 (4), 1-11.

Bircan, H. ve Karagöz, Y. (2003). Box-Jenkins Modelleri ile Aylık Döviz Kuru Tahmini Üzerine Bir Uygulama. Kocaeli Üniversitesi Sosyal Bilimler Dergisi , (6) , 49-62 .

Brink, H., Richards, J. W ve Fetherolf, M. (2017). Real-world Machine Learning. Manning.

Box, G. E., Jenkins, G. M., Reinsel, G. C. ve Ljung, G. M. (2015). Time series analysis: forecasting and control. John Wiley & Sons.

Chaffey, D. ve White, G. (2011). Business Information Management: Improving Performance Using Information Systems. Prentice Hall. Second Edition. 620 s.

Choo, C. W. (2002). Information management for the intelligent organization: the art of scanning the environment. Information Today, Inc.. Third edition.

Connneau, A., Kiela, D., Schwenk, H., Barrault, L. ve Bordes, A. (2017). Supervised Learning of Universal Sentence Representations from Natural Language Inference Data.

Çubukcu, F. (1994) Novell Netware İşletim Sistemi(Tüm Uyarlamalar), İstanbul: Türkmen kitabevi.

Davenport, T. H. ve Harris, J.G. (2007). Competing on Analytics, Boston, MA: Harvard Business School Press.

Delen, D. ve Demirkan H. (2013). Data, information and analytics as services. Decision Support Systems, 55, 359–363.

Delen, D. ve Ram S. (2018) Research Challenges and Opportunities in Business Analytics, Journal of Business Analytics, 1:1, 2-12.

Delen, D. ve Zolbanin, H.M. (2018). the Analytics Paradigm in Business Research. Journal of Business Research, 90, 186-195.

Evans, J. R. ve Lindner, C. H. (2012). Business analytics: The next frontier for decision sciences. Decision Line, 43(2), 4-6.

Evans, J. R. (2013). Business analytics (first ed.). Upper Saddle River, NJ, USA: Pearson.

Gröger, C., Schwarz, H. ve Mitschang, B. (2014). Prescriptive analytics for recommendation-based business process optimization. Business Information Systems (BIS) 2014 17th International Conference, 176, 25–37.

Gürtekin, A. (2012) Gerçek Zamanlı Ve Kritik Çalışan Sistemler İçin Modern Geniş Alan Ağ Tasarımı. (Yayınlanmamış Yüksek Lisans Tezi). Ankara: Gazi Üniversitesi Fen Bilimleri Enstitüsü.

Ho, W., Xu, X. ve Dey, P. K. (2010). Multi-criteria decision making approaches for supplier evaluation and selection: A literature review. *European Journal of Operational Research*, 202(1), 16-24.

Kamiloğlu, M. E. (2015) Cisco Packet Tracer Kullanarak Ağ Performansı Değerlendirilmesi. (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: İstanbul Aydın Üniversitesi Fen Bilimleri Enstitüsü.

Kawas, B., Squillante, M. S., Subramanian, D., ve Varshney, K. R. (2013). Prescriptive analytics for allocating sales teams to opportunities. 2013 IEEE 13th International Conference on Data Mining Workshops.

Kohavi, R., Rothleder, N. ve Simoudis, E. (2002). Emerging Trends in Business Analytics. *Communications of the ACM*. 45. 10.1145/545151.545177.

Laitinen, E. K. (2009). Importance of performance information in managerial work. *Industrial Management & Data Systems*, 109(4), ss. 550-569.

Marjanovic, O. (2007). The next stage of operational business intelligence: Creating new challenges for business process management. *System Sciences*, 2007. HICSS 2007. 40th Annual Hawaii International Conference On, 215c-215c.

Mitchell, T. (1997). *Machine Learning*, ABD: McGraw-Hill.

Nicholls, C. (2006). BI 2.0 - How Real Time Business Intelligence is Irrevocably Changing the Way that we do Bussiness - In *Search Insight*.

Olah, C. (2015). Understanding LSTM Networks. [colah.github.io: colah.github.io/posts/2015-08-Understanding-LSTMs/](https://colah.github.io/posts/2015-08-Understanding-LSTMs/) (19.03.2020).

Pirttimäki, V. (2007). Business Intelligence as a Managerial Tool in Large Finnish Companies. Thesis for the degree of Doctor of Technology. Tampere University of Technology.

Rausch, P., Sheta, A. F., ve Ayesh, A. (2013). Business intelligence and performance management: Theory, systems and industrial applications. Springer Science & Business Media.

Reisoğlu, E. (2008) Kablosuz Ağlarda Güvenlik. (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: Bahçeşehir Üniversitesi Fen Bilimleri Enstitüsü.

Schniederjans M., Schniederjans D. ve Starkey C. (2014). Business Analytics Principles, Concepts, and Applications: What, Why, and How, Pearson Education Inc., s.4

Sharda, R., Delen, D., ve Turban, E. (2014). Business Intelligence: A Managerial Perspective on Analytics. Third Edition. Prentice Hall Press.

Shmueli G., ve Koppius O.R. (2011). Predictive analytics in information systems research. MIS Quarterly, 35(3), 553-572.

Taylor, S.J. ve Letham, B. (2018). Forecasting at Scale. The American Statistician, 72:1, 37-45.

Thierauf, R. J. (2001). Effective business intelligence systems. Greenwood Publishing Group.

Thompson, O. (2004). Business Intelligence Success, Lessons Learned. <http://www.technologyevaluation.com/research/article/Business-Intelligence-Success-Lessons-Learned.html> (18.03.2020).

Van Calster, T., Baesens, B. ve Lemahieu, W. (2017). ProfARIMA: a profit-driven order identification algorithm for ARIMA models in sales forecasting. Applied Soft Computing, 60, 775-785.

Villanova University Business Articles. The growing importance of business analytics. <https://taxandbusinessonline.villanova.edu/resources-business/article-business/the-growing-importance-of-business-analytics.html> (18.03.2020)

Vuori, V. (2006). Methods of defining business information needs. *Frontiers of e-Business Research ICEB+ eBRF*, 2006, ss. 311-319.

Watson, H. J. ve Wixom, B. H. (2007). The current state of business intelligence. *Computer*, 40(9), ss. 96-99.

Watson, H. J. (2009). Tutorial: business intelligence - Past, present, and future. *Communications of the Association for Information Systems*, 25(1), 39.