



T.C.
NEVŞEHİR HACI BEKTAŞ VELİ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİMDALI

**BÜYÜK VERİ VE MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE
TEDARİK ZİNCİRİ YÖNETİMİ ÜZERİNE BİR UYGULAMA**

Doktora Tezi

Serkan DERİCİ

Danışman
Prof. Dr. Nuri Özgür DOĞAN

Nevşehir
Temmuz 2023



T.C.
NEVŞEHİR HACI BEKTAŞ VELİ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİMDALI

BÜYÜK VERİ VE MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE
TEDARİK ZİNCİRİ YÖNETİMİ ÜZERİNE BİR UYGULAMA

Doktora Tezi

Serkan DERİCİ

Danışman
Prof. Dr. Nuri Özgür DOĞAN

Nevşehir
Temmuz 2023

BİLİMSEL ETİĞE UYGUNLUK

Bu alıřmadaki tm bilgilerin, akademik ve etik kurallara uygun bir řekilde elde edildiđini beyan ederim. Aynı zamanda bu kural ve davranıřların gerektirdiđi gibi, bu alıřmanın znde olmayan tm materyal ve sonuları tam olarak aktardıđımı ve referans gsterdiđimi belirtirim.

Tezi Hazırlayan
Serkan DERİCİ

TEZ YAZIM KILAVUZUNA UYGUNLUK

“Büyük Veri ve Makine Öğrenmesi Yöntemleriyle Tedarik Zinciri Yönetimi Üzerine Bir Uygulama” adlı Doktora tezi, Nevşehir Hacı Bektaş Veli Üniversitesi Sosyal Bilimler Enstitüsü Lisansüstü Tez Yazım Kılavuzu’na uygun olarak hazırlanmıştır.

Tezi Hazırlayan
Serkan DERİCİ

Danışman
Prof. Dr. Nuri Özgür DOĞAN

İşletme Ana Bilim Dalı Başkanı
Prof. Dr. Korhan KARACAOĞLU

KABUL VE ONAY SAYFASI

Prof. Dr. Nuri Özgür DOĞAN danışmanlığında Serkan DERİCİ tarafından hazırlanan “*Büyük Veri ve Makine Öğrenmesi Yöntemleriyle Tedarik Zinciri Yönetimi Üzerine Bir Uygulama*” adlı bu çalışma jürimiz tarafından Nevşehir Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı’nda Doktora Tezi olarak kabul edilmiştir.

10/07/2023

JÜRİ

İMZA

Danışman : Prof. Dr. Nuri Özgür DOĞAN
Üye : Doç. Dr. Aylin ALKAYA
Üye : Doç. Dr. İlhan GÜLLÜ
Üye : Doç. Dr. Yusuf ERSOY
Üye : Dr. Öğr. Üyesi Gökhan SEÇME

ONAY:

Bu tezin kabulü Enstitü Yönetim Kurulunun / / tarih ve sayılı Kararı ile onaylanmıştır.

..... / /

Dr. Öğr. Üyesi Volkan Recai ÇETİN
Enstitü Müdürü

TEŐEKKÜR

Tez alıőmamın hazırlanmasında ve akademik gelişimimde her an gerekli yardım ve desteęi esirgemeyen danışmanım Prof. Dr. Nuri Özgür DOĞAN'a sonsuz teşekkür ederim. Ayrıca tez alıőmam boyunca bana zamanlarını ayıran ve değerli bilgilerini paylaşan hocalarım Do. Dr. Aylin ALKAYA'ya, Do. Dr. İlhan GÜLLÜ'ye ve Dr. Öğretim Üyesi Gökhan SEÇME'ye çok teşekkür ederim. Son olarak tez alıőmam sırasında destek ve anlayışını esirgemeyen aileme, eşim Esmâ YILDIRIM DERİCİ'ye teşekkür ederim.



BÜYÜK VERİ VE MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE TEDARİK ZİNCİRİ YÖNETİMİ ÜZERİNE BİR UYGULAMA

Serkan DERİCİ

Nevşehir Hacı Bektaş Veli Üniversitesi, Sosyal Bilimler Enstitüsü

İşletme Anabilim Dalı, Doktora, Temmuz 2023

Danışman: Prof. Dr. Nuri Özgür DOĞAN

ÖZET

Tedarik zinciri yönetimi, bir ürünü oluşturan hammaddelerin temininden tüketicilerden geri dönüşlere kadar olan tüm süreci kapsayan bir disiplindir. Günümüzde dijitalleşme ve altyapı çalışmalarının etkisiyle tedarik zincirleri klasik yapıdan çıkarak yüksek miktarda veri içeren ve teknolojik donanımların kullanıldığı bir yapıya dönüşmüştür. Bu kapsamda tedarik zinciri ağında yer alan her bir aşamada sensörler yoğun olarak kullanılmaya başlanmıştır. Sensörlerin yoğun olarak kullanılması ile beraber klasik tedarik zinciri yönetimleri nesnelerin interneti (IoT) tabanlı tedarik zinciri yönetimi olarak isimlendirilmeye başlanmıştır. IoT tabanlı tedarik zinciri yönetiminde, taşımada kullanılan araçlardan ürünlerin satıldığı raflara kadar her bir aşama ve gereçte sensörler kullanılmaktadır. Bu sensörler ile anlık veriler elde edilmekte ve tüm sürece dair büyük veriler ortaya çıkmaktadır. Makine öğrenmesi ise elde edilen söz konusu büyük miktardaki verilerin analiz edilmesi için geliştirilen yapay zekâ tabanlı algoritmalarıdır. Tedarik zinciri yönetimi literatürü incelendiğinde zinciri bir bütün olarak ele alan ve makine öğrenmesi ile analizler içeren çalışma sayısının artırılması amacıyla bu tez çalışması tasarlanmıştır. Konunun güncel olması ve literatürdeki eksiklik ele alındığında bu çalışmanın sonuçları önemli bulgular içermektedir. Bu kapsamda bir imalat işletmesinin hammadde temin süreci ve üretim sürecine dair gerçek veriler elde edilmiştir. Elde edilen bu büyük veriler makine öğrenmesi algoritmaları ile Microsoft Azure Machine Learning Studio platformunda analiz edilmiştir. İlk kısımda linear regresyon uygulaması yapılarak hammadde tedarik sürecinde gecikmeler tespit edilmiş ve gelecek dönemlere dair tahminler geliştirilmiştir. İkinci kısımda, öncelikle tedarik zinciri sürecine dair veriler arasında anlamlı ilişkilerin tespit edilmesi ve sonraki aşamalara temel olması için değişkenler arasındaki korelasyon ilişkisine, bağımlı değişken üzerindeki etkisinin belirlenmesi için ise regresyon analizi uygulanmıştır. İleri beslemeli bir yapay sinir ağı modeli geliştirilerek gerçekleşen üretim düzeyleri ile makine öğrenmesinin tahmin ettiği üretim düzeyleri karşılaştırılarak ortalama mutlak hatalar tespit edilmiş ve işletmenin üretim verimliliği ifade edilmiştir. Son kısımda ise varsayımsal bir doğrusal programlama modeli geliştirilerek işletmenin üreterek depoladığı ürünleri beş farklı dağıtım merkezine iletmesi problemi LINDO paket programı ile çözülmüştür. Elde edilen sonuçlar ve kullanılan algoritmaların sektör için bir örnek teşkil edeceği ve alandaki boşluğu dolduracağı tahmin edilmektedir. Son olarak ise gelecek araştırmalar için öneriler sunulmuştur.

Anahtar Kelimeler: Tedarik Zinciri Yönetimi, Büyük Veri, Makine Öğrenmesi.

AN APPLICATION ON SUPPLY CHAIN MANAGEMENT WITH BIG DATA AND MACHINE LEARNING METHODS

Serkan DERİCİ

Nevşehir Hacı Bektaş Veli University, Institute of Social Sciences

Business Administration, PhD, July 2023

Supervisor: Prof. Nuri Özgür DOĞAN

ABSTRACT

Supply chain management is a discipline that covers the entire process from the supply of raw materials that make up a product to the returns from consumers. Today, with the effect of digitalization and infrastructure studies, supply chains have left the classical structure and transformed into a structure that contains high amounts of data and technological equipment is used. In this context, sensors have been used intensively at every stage in the supply chain network. With the intense use of sensors, classical supply chain managements have begun to be named as internet of things (IoT) based supply chain management. In IoT-based supply chain management, sensors are used at every stage and equipment, from the vehicles used in transportation to the shelves where the products are sold. With these sensors, instant data is obtained and big data about the whole process emerges. Machine learning, on the other hand, is artificial intelligence-based algorithms developed to analyze the large amount of data obtained. When the supply chain management literature is examined, it is seen that there is a lack of studies that deal with the chain as a whole and include machine learning and analysis. The results of this study contain important findings when the topic is up-to-date and the gap in the literature is considered. In this context, real data on the raw material procurement process and production process were obtained by considering the supply business of a manufacturing company. This big data obtained was analyzed with machine learning algorithms on Microsoft Azure Machine Learning Studio platform. In the first part, supply delays were determined by applying linear regression and forecasts for future periods were developed. In the second part, firstly, regression analysis was applied to determine the significant relationships between the data on the supply chain process and to determine the correlation between the variables to be the basis for the next stages, and to determine the effect on the dependent variable. In the continuation, a feed forward artificial neural network model was developed and the actual production levels were compared with the production levels predicted by machine learning, and the average absolute errors were determined and the production efficiency of the enterprise was expressed. In the last part, a hypothetical linear programming model was developed and the problem of the enterprise's production and delivery of the products it stored to five different distribution centers was solved with the LINDO package program. It is estimated that the results obtained and the algorithms used will set an example for the sector and fill the gap in the field. Finally, suggestions for future research are presented.

Keywords: Supply Chain Management, Big Data, Machine Learning.

İÇİNDEKİLER

	Sayfa No.
BİLİMSEL ETİĞE UYGUNLUK	ii
TEZ YAZIM KILAVUZUNA UYGUNLUK	iii
KABUL VE ONAY SAYFASI	iv
TEŞEKKÜR.....	v
ÖZET	vi
ABSTRACT.....	vii
İÇİNDEKİLER	viii
TABLolar LİSTESİ.....	x
ŞEKİLLER LİSTESİ	xi
GİRİŞ	1

BİRİNCİ BÖLÜM KAVRAMSAL ÇERÇEVE

1.1. TEDARİK ZİNCİRİ YÖNETİMİ.....	3
1.1.1. Tedarik Zinciri ve Tedarik Zinciri Yönetimi	4
1.1.2. Tedarik Zinciri Yönetiminin Tarihsel Gelişimi.....	7
1.1.3. Tedarik Zinciri Yönetiminin Temel Fonksiyonları	12
1.1.4. Tedarik Zinciri Yönetiminin Amaçları.....	21
1.1.5. Tedarik Zinciri Yönetiminin Önemi.....	23
1.1.6. Tedarik Zinciri Yönetiminin Faydaları	24
1.1.7. Tedarik Zinciri Ağ Tasarımı.....	26
1.1.8. IoT Tabanlı Tedarik Zinciri Yönetimi.....	30
1.2. BÜYÜK VERİ VE BÜYÜK VERİ ANALİĞİ.....	36
1.2.1. Büyük Veri Kavramı	39
1.2.2. Büyük Verinin Tarihçesi	41
1.2.3. Büyük Verinin Bileşenleri.....	42
1.2.4. Büyük Veri Kaynakları.....	45
1.2.5. Büyük Veri Kullanımını Teşvik Eden Nedenler	49
1.2.6. Büyük Verinin Kullanım Alanları	50
1.2.7. Büyük Verinin Avantaj ve Dezavantajları	51

1.2.8. Büyük Veri Analitiği	52
1.3. MAKİNE ÖĞRENMESİ	59
1.3.1. Makine Öğrenmesi Kavramı	62
1.3.2. Makine Öğrenmesi Aşamaları	66
1.3.3. Makine Öğrenmesi Metotları	68
1.3.3.1. Danışmanlı Öğrenme (Supervised Learning)	70
1.3.3.1.1. Regresyon.....	71
1.3.3.1.2. Sınıflandırma Algoritmaları	73
1.3.3.1.2.1. Destek Vektör Makineleri	74
1.3.3.1.2.2. Yapay Sinir Ağları.....	77
1.3.3.1.2.3. K-En Yakın Komşu	88
1.3.3.1.2.4. Rastgele Ormanlar	90
1.3.3.1.2.5. Naive Bayes.....	92
1.3.3.1.2.6. Karar Ağaçları	92
1.3.3.1.3. Danışmansız Öğrenme	94
1.3.3.1.4. Yarı Danışmanlı Öğrenme	99
1.3.3.1.5. Takviyeli Öğrenme.....	100
1.4. Literatür Taraması.....	102

İKİNCİ BÖLÜM

BÜYÜK VERİ VE MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE TEDARİK ZİNCİRİ YÖNETİMİ ÜZERİNE BİR UYGULAMA

2.1. Uygulama Yapılan Firma Hakkında Bilgi	110
2.2. Araştırmanın Amacı	112
2.3. Araştırmanın Önemi.....	112
2.4. Araştırmanın Kapsam ve Yöntemi.....	112
2.5. Uygulama	113
2.5.1. Makine Öğrenmesi ile Teslim Süresi Tahmini.....	123
2.5.2. Makine Öğrenmesi ile Yapay Sinir Ağı Uygulaması.....	126
2.5.3. Ürün Dağıtımını için Varsayımsal Bir Doğrusal Programlama Modeli.....	133
2.6. SONUÇ	135
KAYNAKÇA	141

TABLULAR LİSTESİ

Tablo 1. 1. Tedarik Zinciri Yönetiminde Anahtar Boyutlar ve Gereklilikler	14
Tablo 1. 2. Büyük Veri Kaynakları	47
Tablo 1. 3. Veri Analizi Kategorilerinin Farkları ve Karşılaştırması.....	58
Tablo 1. 4. Yapay Sinir Ağlarının Tarihsel Gelişimi	82
Tablo 1. 5. Biyolojik Sinir Sistemi ve Yapay Sinir Ağı Eşleştirmesi	85
Tablo 2. 1. Firma Sürecine Dair Değişkenler ve Sınıflandırılması.....	113
Tablo 2. 2. Çoklu Regresyon Analizinde Kullanılan Değişkenler	116
Tablo 2. 3. Değişkenlere İlişkin Betimleyici İstatistikler.....	116
Tablo 2. 4. Korelasyon Analizi Bulguları	118
Tablo 2. 5. Dickey-Fuller Birim Kök Testi Sonuçları.....	118
Tablo 2. 6. F Testi İstatistik Değerleri.....	119
Tablo 2. 7. Hausman Test İstatistiği Sonuçları.....	119
Tablo 2. 8. Geliştirilmiş Wald Testi İstatistik Sonuçları	120
Tablo 2. 9. Otokorelasyon Testi	121
Tablo 2. 10. Pesaran Test İstatistiği Sonuçları	121
Tablo 2. 11. Panel Regresyon Modeli Sonuçları.....	122
Tablo 2. 12. Tedarik Sürecine Dair Bilgiler ve Tedarik Gecikmesi.....	125
Tablo 2. 13. Üretim Sürecine Dair Verilerin Bir Kesiti ve Yapay Sinir Ağı Modelinde Yer Alanlar.....	130
Tablo 2. 14. Denenen Yapay Sinir Ağı Modellerinden Bir Kesit	131
Tablo 2. 15. Yapay Sinir Ağı Uygulama Sonuçları	132
Tablo 2. 16. Taşıma Maliyetleri, Kapasiteler ve İhtiyaçlar.....	134
Tablo 2. 17. Elde Edilen Sonuçlar ve Dağıtım Miktarları.....	135

ŞEKİLLER LİSTESİ

Şekil 1. 1. Tedarik Zinciri Yönetiminin Seviyeleri	13
Şekil 1. 2. Tedarik Zinciri Yönetiminde Anahtar Boyutlar	14
Şekil 1. 3. Tedarik Zinciri Yönetiminin Fonksiyonları	16
Şekil 1. 4. Genel Tedarik Zinciri Ağ Yapısı.....	27
Şekil 1. 5. Geleneksel Tedarik Zincirinin IoT Tabanlı Tedarik Zincirine Dönüşümü	33
Şekil 1. 6. IoT Tabanlı Tedarik Zincirini Oluşturan Disiplinler ve Bileşenleri	34
Şekil 1. 7. Büyük Verinin Bileşenleri (6V)	45
Şekil 1. 8. Büyük Veri Mimarisi	48
Şekil 1. 9. Veri Bilimi Alanları	53
Şekil 1. 10. Büyük Veri Analitiğinin Temel Aşamaları	54
Şekil 1. 11. Büyük Veri Analitiği Sistemi.....	55
Şekil 1. 12. Büyük Veri Analitiği Kategorileri.....	56
Şekil 1. 13. Tahmine Dayalı (Predictive) Analiz Süreci	56
Şekil 1. 14. Büyük Veri Analitiği Algoritmaları	59
Şekil 1. 15. Makine Öğrenmesi Aşamaları.....	67
Şekil 1. 16. Makine Öğrenmesi Metotlarının Sınıflandırılması	69
Şekil 1. 17. Danışmanlı Öğrenme	71
Şekil 1. 18. Makine Öğrenmesinde Doğrusal Regresyon Modeli	72
Şekil 1. 19. Sınıflandırma.....	74
Şekil 1. 20. Sınıfları Ayıran Doğru	75
Şekil 1. 21. İki Sınıflı Bir Veri Kümesinde Hiperdüzlemi Marjın ve Destek Vektörleri	76
Şekil 1. 22. Makine Öğrenmesinde Bir Yapay Sinir Ağı Yapısı.....	77
Şekil 1. 23. Basit Bir Yapay Sinir Ağı Yapısı.....	83
Şekil 1. 24. Basit Bir Biyolojik Sinir Hücresi Yapısı.....	84
Şekil 1. 25. Yapay Sinir Ağı Mimarisi	85
Şekil 1. 26. Yapay Sinir Ağı Modelleri ve Sınıflandırması	86
Şekil 1. 27. İleri Beslemeli Yapay Sinir Ağları.....	87
Şekil 1. 28. Geri Beslemeli Yapay Sinir Ağları	88
Şekil 1. 29. Makine Öğrenmesinde Karar Ağacı Yapısı	93
Şekil 1. 30. Danışmansız Öğrenme	95
Şekil 1. 31. Kümeleme	96
Şekil 1. 32. Yarı Danışmanlı Öğrenme	99
Şekil 1. 33. Takviyeli Öğrenme.....	101

Şekil 1. 34. Q-Learning Akış Şeması	101
Şekil 2. 1. Ön Şişirme ve Blok Bölümü İş Akışı.....	111
Şekil 2. 2. Tedarikçilere Göre Sipariş Sayıları	114
Şekil 2. 3. Üretim Alanı ve Tedarikçilerin Gösterimi	115
Şekil 2. 4. Tedarik Gecikmesine Dair Regresyon Modeli Akışı	124
Şekil 2. 5. Geliştirilen İleri Beslemeli Çok Katmanlı Yapay Sinir Ağı Yapısı	127
Şekil 2. 6. Microsoft Azure Machine Learning Studio Yapay Sinir Ağı Akışı.....	128
Şekil 2. 7. Çalışmanın Uygulama Adımları	129
Şekil 2. 8. Depolar ve Dağıtım Merkezleri	133



GİRİŞ

Tedarik zinciri yönetimi, 2011’de ilan edilen Endüstri 4.0 ile birlikte dijitalleşmenin etkisinin en fazla görüldüğü sektörlerin başında gelmektedir. Bu doğrultuda işletmeler tüm zincir ağı boyunca dijital teknolojileri içeren unsurları yoğun olarak kullanmaktadır. Tüm süreç içerisinde yer alan verileri doğru ve etkili analiz ederek faydalı sonuçlar çıkarmak tüm zincirin başarısının yanında tedarik zinciri ağı içerisinde yer alan tüm işletmelerin başarısını da ayrı ayrı etkilemektedir.

Günümüzde tedarik zincirleri tüm ağı kapsayacak bilgi teknolojileriyle donatılmıştır ve bilgi ile veri akışı eş anlı olarak diğer işletmeler ile paylaşılmaktadır. Bu durum işletme bir sipariş aldığı anda hammadde tedarikçisine kadar iletilen bir akışı kapsamaktadır. Yine aynı şekilde hammadde temininde yaşanabilecek bir problem fark edildiğinde tedarikçiler üretim işletmelerine, bu işletmelerde satıcılara bu bilgiyi iletmektedir. Tedarik zinciri ağına gerçekleştirilen ilk aşamadan son aşamaya kadar olan süreçte her bir adımda sensörler kullanılarak bilgiler anlık olarak bilgisayar ortamına aktarılmaktadır. Sürecin her aşamasına ait olan bu veriler devasa boyutlara ulaşabilmektedir. Bu durumda tedarik zincirinde büyük veri yönetimi kavramını ön plana çıkarmakta ve günümüzde bu verilerin analizi işletmeler için önemli bir sorun olmaktadır. Tedarik zinciri ağı boyunca her bir aşamada sensörlerin kullanılması, büyük veri analizini zorunlu kılarken tedarik zinciri yönetimini ise IoT (nesnelerin interneti) tabanlı tedarik zinciri yönetimine çevirmektedir. IoT tabanlı tedarik zinciri yönetiminde üretimde kullanılacak hammadde temin sürecinden raftan bir ürünün müşteriye satılmasına kadar olan tüm sürece dair anlık hareketler veri olarak bilgisayar ortamına aktarılmakta ve bulut bilişim aracılığıyla depolanmaktadır. Günümüzde bir işletmenin ürettiği bir ürün müşteri tarafından satın alındığında, stoktan bir birim düşme bilgisi anlık olarak hem satıcı işletmeye hemde üretim işletmesine iletilmektedir. Üretim işletmesi müşterileri olan satıcıların elindeki stok miktarının azaldığını bu şekilde takip ederek üretim planlamakta; üretim işletmesinin elinde bulunan hammadde stoğunun parçalar halinde üretime sokulması durumunda ise hammadde tedarikçisi hammadde hazırlamaya başlamaktadır. Bu yapıdaki tedarik zinciri yönetimi IoT tabanlı tedarik zinciri yönetimi olarak isimlendirilmektedir. IoT tabanlı tedarik zinciri yönetimi sürece dair tüm bilgilerin doğru ve zamanında analiz

edilerek politikalar geliřtirmede ve sistemin kusursuz iřlemesinde byk olduka nemlidir.

Makine ğrenmesi algoritmaları ise temelde makinelerin insan gibi dřnme yetisi kullanması iin geliřtirilen bilgisayar tabanlı uygulamalardır. Byk veri setleri ve ok fazla deęiřken ile analizler yapılırken hataların minimize edilmesi ve daha etkin sonular elde edilmesi iin makine ğrenmesi algoritmalarını kullanmak klasik analiz trlerine gre nemli stnlkler saęlamaktadır. Bir dięer yandan, sisteme girilen veriler makine tarafından ğrenilerek benzer durumlar altında karar vermek amacıyla makineler tahminler ortaya koyabilmekte bu durumda iřletmeler iin olduka nemli bilgiler ortaya ıkarmaktadır.

Literatrde makine ğrenmesi ve tedarik zinciri ynetimi kavramlarını ele alan alıřmaların genelinin teorik anlamda kaldıęı ya da literatr taraması řeklinde alıřmalar olduęu grlmektedir. Az sayıda da olsa sipariř gecikmesi ve satıř tahmini konularını ele alan alıřmalarda bulunmaktadır. Ancak bir tedarik zincirini bir aę řeklinde tamamen ele alan alıřma bulunmamaktadır. Bu bakımdan bu tez alıřması, tedarik zinciri ve makine ğrenmesi konularını bir arada ele alan bir tasarıma sahiptir. alıřmanın sonuları alana kkte olsa bir katkı saęlayacaktır.

Bu tez alıřması kavramsal ereve ve uygulama olmak zere iki kısımda tasarlanmıřtır. Kavramsal ereve blmnde ise tedarik zinciri ynetimi, byk veri ve byk veri analitięi ile makine ğrenmesi kavramları ana bařlıklar olarak aıklanmıřtır. alıřmanın ikinci kısmında ise bir retim iřletmesinin tedarik ve retim srelerine dair byk veriler elde edilerek makine ğrenmesi algoritmaları ile analiz edilmiřtir. Bu kapsamda bir tedarik zinciri ele alınmıř; hammadde tedariki ve retim srecine dair gerek veriler makine ğrenmesi algoritmaları kullanılarak analiz edilmiřtir. retilen rnlerin daęıtım srecine dair iřletmeden veri alınamadıęı iin varsayımsal bir doęrusal programlama modeli gerek retim verileri ve iřletmenin kapasitesine gre tasarlanarak ele alınmıř ve zlmřtr.

BİRİNCİ BÖLÜM

KAVRAMSAL ÇERÇEVE

Günümüz rekabet koşullarında etkin tedarikçi seçimi, yönetimi ve gelişimi, şirketlerin hedeflerine ulaşabilmeleri için büyük önem taşımaktadır. Çünkü alınan malzemenin üretilen ürün üzerindeki etkisi düşünüldüğünde, üretimde kullanılan malzemenin kalitesi, maliyeti, zamanında teslimi gibi faktörler ne kadar iyi olursa, üretilen malın piyasada değeri o kadar yüksek olmaktadır. Bu da işletmeye rekabet avantajı sağlamaktadır. Ortaklığın başarısını desteklemek için üreticiler, tedarikçiler ve tedarikçilerin tedarikçileri arasında tam bir işbirliği gerekmektedir. İşletmeler uygun tedarikçileri belirledikten ve onlar hakkında bilgi topladıktan sonra, belirlenen kriterlere göre potansiyel tedarikçileri değerlendirmektedirler (Paksoy vd. 2021).

1.1. TEDARİK ZİNCİRİ YÖNETİMİ

Tedarik zincirleri, bir ürün veya hizmeti tasarlamak, üretmek, teslim etmek ve kullanmak için faaliyet gösteren şirketleri ve ticari faaliyetleri kapsamaktadır. İşletmeler, hayatta kalmak ve gelişmek için ihtiyaç duydukları şeyleri sağlamak amacıyla tedarik zincirlerine bağlıdır. Her işletme bir veya daha fazla tedarik zincirine tabidir ve her birinde farklı bir rol oynamaktadır. Değişimin hızı ve piyasaların nasıl gelişeceğine dair belirsizlik, şirketlerin katıldıkları tedarik zincirlerinin farkında olmalarını ve oynadıkları rolleri anlamalarını giderek daha önemli hale getirmiştir. Güçlü tedarik zincirleri kurmayı ve bunlara katılmayı öğrenen şirketler, kendi pazarlarında önemli bir rekabet avantajına sahip olacaklardır.

Kıt kaynakların optimum bir şekilde kullanılmasında ve işletmelerin kâr elde ederek yaşamını devam ettirmesinde anahtar bir role sahip olan tedarik kavramı ve kusursuz bir plan içerisinde işlemesi gereken bir mekanizma olarak tedarik zinciri yönetimi kavramları günümüzün her alanında hayati role sahiptir. 2020 yılında yaşanmaya başlayan ve halen etkileri görülen Covid-19 pandemisi tedarik zincirlerinin önemini

artırmış; dijital tedarik zincirlerini ve teknoloji kullanımını ileri boyuta taşımıştır. Konunun önemi akademik çalışmalara da yansımış ve sadece Covid-19 pandemisinin başladığı 2020 yılından beri Google akademik verilerine göre yaklaşık 421.000 bilimsel çalışma yapılmıştır. Bir diğer yandan son dönemde ülkemizde yaşanan yangın, sel ve deprem gibi doğal afetlerde tedarik zincirlerinin önemini arttırmıştır. Bu bakımdan günümüzde en önemli kavramların başında gelen tedarik ve tedarik zinciri kavramlarının bilinmesi önem arz etmektedir.

1.1.1. Tedarik Zinciri ve Tedarik Zinciri Yönetimi

Tedarik kavramı, 1900'lü yılların başında ilk olarak Forrester tarafından ortaya atılmıştır. Forrester, tedarik işlerinin işletmelerde, bütünleştirilmiş bir yapıda ele alınması gereken, dağıtım kanalları içinde yer alan ve örgütsel ilişkilerin düzenlenmesini sağlayan bir terim olarak tanımlamıştır (Forrester, 1958).

1950'lerden sonraki dönemlerde, kusurlu parçaların yüksek maliyet ortaya çıkarması ve bu maliyetleri düşürmek amacıyla tam zamanlı üretim ve kanban sistemleri kullanılmaya başlanarak (Womack vd., 1990), daha az çeşitlilik ve esnekliğe sahip olan kitle üretim sistemi uygulanmıştır (Ohno, 1988). Fark edilen bu durum ve kullanılan metotlardan yola çıkarak Ohno, tedarik sistemi içindeki parça akışını günlük olarak koordine etmenin yeni bir yolunu geliştirmiştir. Böylece parçalar yalnızca bir sonraki adımın acil talebini karşılamak için bir önceki adımda üretilmeye başlanmıştır (Dahlgaard ve Dahlgaard, 2006). Yaşanılan bu gelişmeler ile beraber, tam zamanında üretim, kanban sistemi ve yalın üretim felsefesi, üretim ve dolayısıyla tedarik zinciri alanında kullanılmaya başlanmıştır.

Yaşanan gelişmeler ile beraber yirminci yüzyılın son döneminde işletmeler kitle üretimi yerine daha müşteri merkezli kararlar almaya başlamıştır. Bu doğrultuda ilk olarak tüm süreci kapsayan aktörler ile iş ilişkilerini geliştirmişlerdir. Daha sonra oluşturulan bu yeni ilişkiler süreci, tedarik zinciri yönetimi olarak isimlendirilmiştir (Calatayud vd., 2018).

Tedarik zinciri ve tedarik zinciri yönetimi kavramları hemen her sektör için farklı bir anlama sahip olduğu için; bireyler genellikle kişisel deneyimlerine dayanarak farklı

tanımlar yapmaktadır (Lu vd., 2015). Literatürde yürütülen çalışmalarda, tedarik zinciri yönetiminin nasıl tanımlandığı ve uygulandığına bağlı olarak farklı anlama geldiği ifade edilmektedir (Fawcett vd., 2002). Tedarik zinciri yönetimi bir terim olarak ifade edilene kadar, bu kavram lojistik ve operasyon yönetimi gibi alt dalları kapsayan kavramlar olarak anılmıştır (Hugos, 2002). Tedarik zinciri yönetimi kavramı, 1980'li yılların sonlarında ön plana çıkan (Cooper vd., 1997), zamanla işletmelerde yöneticilerin sorumluluklarını tanımlamada yaygın olarak kullanılmaya başlanan bir kavramdır (La Londe, 1997).

Başlangıçta tedarik zinciri ve lojistik kavramları aynı manada kullanılsa da; tedarik zinciri kavramının lojistik kavramını kapsayan ve daha fazlası olduğu fark edilmiş ve kavramlar birbirinden ayrılmıştır (Larson ve Rogers, 1998).

Tedarik zinciri tanımı, yazarlar arasında tedarik zinciri yönetimi tanımından daha yaygın görünmektedir (Lambert vd., 1998). La Londe ve Masters (1994) bir tedarik zincirinin, malzemeleri ileriye taşıyan bir dizi firma olduğunu öne sürmüştür. Bu kapsamda, birbirinden bağımsız olan firmalar bir ürünün imalatında ve bir tedarik zincirinde son kullanıcının eline teslim etmede aktif olarak yer almaktadır. Aktif olan bu firmalar hammadde ve malzemeleri üreticilere, montajcılara, üretilen ürünleri toptancılar ve perakendecilere taşımaktadır. Bu süreçte yer alan tüm firmalar tedarik zincirinin bir aktörü olarak ifade edilmektedir. Lambert vd. (1998) tedarik zincirini, pazara ürün veya hizmet getiren firmaların hizalanması olarak tanımlamaktadır.

Tedarik zinciri; envanter, satın alma ve dağıtım kontrol etmeye yönelik tesisler, malzemeler, müşteriler, ürünler ve yöntemler kümesidir. Zincir, bir tedarikçi tarafından hammadde üretiminden başlayarak ve bir ürünün müşteri tarafından tüketilmesiyle sona eren tedarikçiler ve müşterileri birbirine bağlamaktadır. Tedarik zincirinde tedarikçi ile müşteri arasındaki mal akışı birkaç aşamadan geçer ve her aşama birçok tesisten oluşabilmektedir (Sabri ve Beamon, 2000). Son yıllarda, tedarik zinciri ağı (SCN) tasarım problemi, pazar küreselleşmesinin getirdiği artan rekabet nedeniyle önem kazanmaktadır (Thomas ve Griffin, 1996). Tedarik zinciri, tüketicilerin ihtiyaç ve gereksinimlerini gidermek için üreticileri, tedarikçileri,

taşıyıcıları ve toptancı ile perakendecileri içeren bir sistem olarak çalışmaktadır (Chopra vd., 2007).

Christopher (1992) tarafından yapılan tanıma göre tedarik zinciri, işletmelerin üreterek tüketicilerin kullanımına sunduğu ürünlerin ortaya çıkarılış sürecinde yer alan birimler arasındaki bağlantıların kurulduğu yapıdır.

Zijm vd. (2019) ise tedarik zincirini, ham maddelerin işlenerek ürünlerin üretilmesi, parçaların birleştirilmesi ve oluşturulan ürünlerin pazarlara iletilmesi sürecinde yapılan taşımacılığa ve depolamaya dair faaliyetler bütünü olarak tanımlamıştır.

Tedarik zinciri yönetimi (TZY), maliyetlerin en aza indirilmesini sağlamak için hammaddelerin tedarik edilmesinden bitmiş ürünün nihai tüketiciye dağıtımına kadar bir organizasyondaki mal akışıyla ilgili tüm bu yönetim faaliyetlerini ifade eder ve içerir. Tedarik zinciri faaliyetleri, üretim ve imalat, kaynak bulma, nakliye, envanter ve depo yönetimi ve nakliye dahil olmak üzere ürün geliştirmeden lojistiğe kadar her şeyi kapsar (Kothari vd., 2018).

Hendry vd. (1991) tedarik zinciri yönetimini; hammaddelerin, üretim sürecinde yer alan hammadde ve malzemelerin, mamul stoklarının üretim noktasından tüketim noktasına kadar yönetimini ve tedarikçilerden son müşterilere kadar malzeme ve bilgilerin planlanması ve kontrolü olarak da tanımlanmıştır.

Tedarik Zinciri Konseyi (2008)'ne göre tedarik zinciri yönetimi; üretimde gereken madde ve malzemelerin talebe göre temin edilmesi, ürünlerin üretilmesi ve montaj işlerinin yapılması, nihai ürünlerin depolanması ve stokların takip edilmesi, tüketicilerden gelen siparişlerin yönetimi ile tüm süreçteki dağıtım faaliyetlerinin yönetimini kapsayan bir terimdir.

Hobbs (1996) tedarik zinciri yönetimini, zincirin organize edilmesi, işletme içi düzenlemeler, sektöre etkileri, işletme bazında değil tüm sektörün verimliliğini, etkinliğini ve karlılığını belirleyen farklı disiplinleri içeren bir yönetim tarzı olarak açıklamıştır.

Harjeet vd (2016) göre ise tedarik zinciri yönetimi, mal ve hizmetlerin nakliyesinin veya akışının yönetimidir. Bu süreç aynı zamanda depolama, raf ömrü, tedarik edilen malların analizi ve satılan malların lojistiği gibi faaliyetleri içerir.

İşletmelerin üretim süreçleri ve işletme politikalarına dair alınan kararlar zincir içerisinde paylaşılarak etkinlik arttırılmalıdır. Bu nedenle birbirine entegre edilmiş aktörlerden oluşan bir tedarik zinciri yönetimi içerisinde tüm faaliyetler yatay ve dikey olarak birlikte hareket eden bir aktörlerden oluşmaktadır (Monczka ve Morgan,1997). Tedarik zinciri yönetimi, çeşitli tedarik zinciri faaliyetlerinin planlanmasına ve yürütülmesine yardımcı olur. Tedarik zinciri yönetimi herhangi bir mal veya hizmetin arz ve talebine ilişkin mevcut piyasa eğilimini belirlemek ve bunları kuruluşun performansını ölçmek için senkronize etmek için etkin bir şekilde geliştirilmesi ve yürütülmesi gereken bir süreç olarak ele alınmalıdır (Harjeet vd., 2016).

Tedarik Zinciri Yönetimi'nin literatürde yapılan tanımlamalar ve açıklamalardan yola çıkılarak, tedarik zinciri yönetiminin beş temel amacının olduğu ifade edilebilir (Özdemir, 2004):

- Müşteri tatminini maksimize etmek,
- Ürün çevrim süresini minimize etmek,
- Depolama ve taşıma maliyetlerini minimize etmek,
- Üretimde hataları ortadan kaldırmak ya da en az düzeye indirmek,
- Tüm zincirin maliyetini düşürmek.

Tedarik zinciri yönetimi kavramının hangi anlamı taşıdığı detaylı olarak açıklandıktan sonra, TZY'nin tarihsel süreç içerisinde gelişiminin açıklanması yerinde olacaktır.

1.1.2. Tedarik Zinciri Yönetiminin Tarihsel Gelişimi

Dinamik bir sistem olan tedarik zincirinin gelişim sürecini bilmek, karşılaşılan problemlere çözüm bulabilmek açısından önemlidir. Tedarik zincirlerinin gelişimi incelendiğinde sanayi devrimleri ve getirdikleri yeniliklerin doğrudan etkili olduğu görülmektedir. Bu bakımdan ülke ekonomilerinin ve sanayilerinin gelişmesi,

uluslararası ticaretin gelişmesi tedarik zincirlerinin gelişimi ile doğrudan orantılı olmuştur.

Tedarik zinciri ve lojistiğin tarihsel evrimi incelendiğinde şu hususlar tespit edilmiştir (Frazzon vd. 2019):

- Lojistik 2.0, Endüstri 2.0'dan neredeyse bir asır sonra başlar;
- Aşama 3.0, tüm alanlar için neredeyse aynı zamanda başlamıştır (Endüstri 3.0, 1969; Lojistik 3.0, 1980; SCM 3.0, 1985);
- SCM 3.0'ın (SCM'nin ilk aşaması) özellikleri ve tekniklerinin endüstri 3.0 ve lojistik 3.0 ile daha uyumludur.
- SCM 1.0 ve SCM 2.0 aşamalarının yoktur;
- SCM 4.0 hala ideal olgunluğuna ulaşmamıştır.

Geçmiş dönemlere bakıldığında değişen talep, gelişen teknoloji gibi faktörlere bağlı olarak klasik tedarik zincirlerinde nakliyecilerin müşterilere cevap verebilmek amacıyla farklı üreticileri bir araya getirmesi, günümüz tedarik zincirlerinin temelini oluşturmuştur. İşgücüne dayalı olan mekanik sistemlerin kullanılmadığı atölye tipi üretim, buharlı makinelerin icat edilmesiyle birlikte yerini makinelere bırakmaya başlamıştır. Buharlı makinelerin sanayide kullanılmaya başlaması demir işlemeyi olanaklı hale getirmiştir. 1800'lü yıllarda artan nüfus ve göç hareketlerine ek olarak, demirin işlenmeye başlamasıyla beraber demiryolu ulaşımının gelişmeye başlaması üretilen ürünlerin taşınmasını olanaklı hale getirmiştir.

1900'lü yıllara geldiğimizde nakliyecilik alanında en büyük yeniliğin paletlerin icat edilmesi olduğunu görmekteyiz. Paletler ile birlikte nakliyeciler ürünleri tek bir sevkiyat içerisinde taşımaya başlamıştır. Taşımacılık alanında yaşanan bu gelişme planlama ve taşıma yöntemlerinin gelişmesine neden olmuştur. İkinci Dünya Savaşı esnasında tedarik zincirlerinin rakipler tarafından ana hedef haline gelmesi ise denizyolu taşımacılığının gelişmesine sebep olmuştur. Denizyolu taşımacılığının ilk olarak ilkel olabilecek bir şekilde gelişmeye başlaması ve devamında konteynırların kullanılmaya başlanarak taşıma kapasitelerinin optimize edilme çalışmaları günümüzdeki küresel tedarik zincirlerinin temelini oluşturmuştur.

1950'li yıllar lojistik ve tedarik zinciri alanında ulaşım dönemi olarak geçmektedir. Aynı zamanda lojistik ve tedarik zinciri alanında hareketsiz dönem (Ballou, 1978) olarak da tanımlanan bu dönem bilgisayarların ve cep tipi hesap makinelerinin kullanılmadığı, üniversitelerde bile lojistik ve tedarik zinciri konularında derslerin verilmediği (Southern, 2011), ana aktörün hükümetler olduğu, hemen hemen hiçbir alanda optimizasyonun olmadığı dönemdir. Taşımacılıkta birim yük kavramının kullanıldığı bu dönemde lojistik ve tedarik zinciri konuları askeri ağırlıklı olarak kullanılmıştır. Bu dönemde savaş anında ihtiyaç duyulan malzemelerin, tam zamanında üretim felsefesine benzer bir düşünce tarzıyla ihtiyaç duyulan yerlere ulaştırılması ana düşünce noktasını oluşturmuştur. Bu dönemde askeri bir terim olarak anılan lojistik kavramı (Ballou, 1978); askeri tesislerin kurulması, personelin tedarik edilmesi, malzemelerin taşınması ile ilgili olarak görülmüştür (Habib, 2014).

Fiziksel dağıtım dönemi olarak geçen 1960'lı yıllara gelindiğinde (Heskett vd., 1973) bilgisayarların tedarik zinciri alanında kullanılmaya başlanması, optimizasyon problemlerinin ele alınmasını olanaklı kılmıştır. Tedarik zinciri sistemlerinin parçalar halinde olduğu ve birbirinden bağımsız görüldüğü (Rodrigue, 2020) bu dönemde 1950'li yıllarda başlayan ulaşım dönemi, az ölçüde de olsa lojistik ve tedarik zinciri çalışmalarına dönüşerek fiziksel dağıtım başlanmıştır. 1961 yılında Jay Forrester *Industrial Dynamics* isimli kitabında kamçı etkisini tanımlamıştır (Forrester, 1997). 1963 yılında sonradan ismi *Tedarik Zinciri Yönetimi Profesyonelleri Konseyi* olarak değişen ve günümüzde yaklaşık on beş bin üyesi bulunan *Ulusal Fiziksel Dağıtım Yönetimi Konseyleri* kurulmuştur. Aynı zamanda fiziksel dağıtım alanında kamyonların kullanılmaya başlanması yük taşımacılığında demiryolu ve denizyoluna ek olarak karayolunun da kullanılmasını sağlamıştır. Bu dönemde tedarik zinciri ve lojistik konularında ilk çalışmalar yapılmaya başlanmıştır. Sözelimi alandaki ilk ders kitaplarından birisi olan ve Smykay vd. (1961) tarafından yazılan *Logistics Management: Logistics Problems* yayımlanmıştır. Akademik alanda ilginin oluşmaya başlamasıyla birlikte Amerikan Ulaştırma Derneği, Ulaştırma Dergisi'nin ilk sayısını bu dönemde (1961) yayımlamıştır.

Fiziksel tedarikin ön planda olduğu 1970'li yıllarda fiziksel dağıtıma ek olarak fiziksel temas konusu gündeme gelerek bu iki davranışın birleştirilmesi üzerine çalışmalar

gerçekleştirildi. Aynı zamanda üniversitelerde dersler verilmeye başlanmış ve bilimsel dergiler, kitaplar ve profesyonel kuruluşlar kurulmuştur (Southern, 2011). 1971 yılında ilk gerçek zamanlı depo sistemi kurulmuştur. 1978 yılına geldiğimizde alanda günümüzün en önde gelen bilimsel dergilerinden birisi olarak görülen *Journal of Business Logistics* Ohio Üniversitesi'nde kuruldu (Miyazaki vd. 1999). Bu dönemde malzeme ihtiyaç planlaması (MRP) tanımlanmış; üretim süreçlerinde tedarik zinciri yönetiminin kalite, maliyet, verimlilik ve teslimat gibi konularda önemli etkisi olduğu vurgulanmıştır (Ross, 1998). Bu bakımdan ele alındığında 1970'ler, teorik alt yapının oluşturulmaya çalışıldığı on yıl olarak görülebilir.

Ulaştırma, deregülyasyon, fiziksel dağıtım ve iş lojistiğinin ortaya çıktığı taşımacılığın serbestleştiği 1980'li yıllarda, tedarik zinciri yönetimi kavramı kullanılmaya başlanmıştır (Habib, 2009). Kişisel bilgisayarların kullanılmaya başlanmasıyla birlikte tedarik zinciri alanında devrimsel nitelikte gelişmelere sahip olmuştur. Bu dönemde tedarik zinciri yönetimi kavramı Keith Oliver tarafından ilk kez kullanılmış ve lojistik alanında çalışan profesyoneller tarafından da kullanılmaya başlanmıştır (Oliver ve Webber, 1992). Tedarik zinciri yönetiminin operasyon yönetimi, sistemler arası entegrasyon ve bilgi paylaşımını içeren şekilde kullanılmasına (Cooper vd. 1997) ek olarak aynı dönemde kişisel bilgisayarlar ile birlikte lojistik planlama ve lojistik teknolojileri gelişmeye başlamasıyla elektronik sistemler uygulanmaya başlamıştır. Bu döneme kadar tedarik zinciri yönetimi kavramı fiziksel dağıtım ve lojistik ile karıştırılmış ve aynı anlamda kullanılmıştır (Ballou, 2007). Yapılan çalışmalar ve yaşanan gelişmeler ile birlikte bu dönemde fiziksel dağıtım terimi yerine lojistik kavramı kullanılmaya başlanmıştır (Rodrigue, 2020). 1985 yılında ilk defa tekstil sektöründe tedarik zincirlerinde hızlı cevap sistemi kullanılmaya başlanmıştır (Hunter ve Valentino, 1995). Uzmanlar bu dönemde, tedarik zincirinin tek bir varlık olarak görülmesi gerektiğini ve tedarik zincirlerini stratejik kararlarda yönetmek için orijinal formülasyonlarında gerekli olduğunu vurgulamışlardır (Gripsrud, 2006). Bu kapsamda işletmeler tüm süreci kapsayan bilgi akışının önemini fark etmiş ve lojistik faaliyetlerinin bütünleştirilmesi üzerine çalışmalar gerçekleştirmişlerdir (Ross, 1998). Tedarik zinciri kavramı özellikle bu dönemde gerçekleştirilen çalışmalar neticesinde önem verilen bir süreç olarak ele alınmaya başlanmıştır (La Londe, 1997).

İşletme lojistiğinin başladığı 1990'lı yıllara geldiğimizde Kurumsal Kaynak Planlamasının (ERP) kullanılmaya başlanması, farklı veritabanlarının birbirine entegre edilmesini olanaklı hale getirerek yaşanan problemlerin çözülmesi kolaylaşmıştır. Bu dönemde ERP ile birlikte veri işleme ve analizi gelişmeye başladı ve son olarak küreselleşme ile birlikte bu dönemde e-ticaret faaliyetleri başladı. Bu gelişmeler ile birlikte işletmeler girdilerin temin edilmesinden ürünlerin tüketicilere ulaştırmasına kadar olan tüm sürecin işletmelerde bir bütün olarak görülmesi gerektiğini fark etmişlerdir (Handfield ve Nicholas, 1998). Tüm sürecin bir bütün olarak görülmesi işletmelerde, tüm faaliyetleri düzenleyen ve denetleyen bir sistem oluşturulmasını gerekli kılmaktadır (Keskin vd. 2004). Optimizasyon yöntemleri ile süreçlerin iyileştirilebileceği ve maliyet tasarrufu sağlanabileceğine yönelik ilk çalışmalar da bu dönemde gerçekleştirilmeye başlanmıştır. Yine bu dönemde internetin hayatımıza girmesi ve elektronik veri transferlerinin yapılmaya başlanması eksiksiz bir entegrasyonun başlamasına neden olmuş (Rodrigue, 2020), üçüncü taraf lojistik organizasyonlarının gelişmesini sağlamıştır. Bu dönemin sonlarında sırasıyla tedarik zinciri ve lojistik alanında kullanılan ilk robot Cobot icat edilmiş ve dünyanın en büyük tedarikçilerinden birisi olan amazon internetin yaygınlaşması ve küreselleşmenin etkisiyle birlikte 1997 yılında halka açılmıştır. Kurt Salmon tarafından 1993 yılında yayımlanan raporda ilk kez etkin müşteri yanıtından tedarik zincirleri için bahsedilmiş; 1999 yılına gelindiğinde ise tedarik zincirlerinde söz konusu program uygulanmaya başlanmıştır (Ferne, 1999).

2000'li yıllarda ise lojistik, tedarik zinciri yönetimi içerisinde bir süreç olarak tanımlanarak birbiriyle aynı anlamda kullanılan bu iki kavram birbirinden ayrıldı. Bu dönemde iş dünyasında tedarik zinciri yönetimi konusu üzerinde bir kabul ve çalışmaların arttırılması gerçekleşmiştir. Bu kapsamda tedarik zincirleri ve lojistik, kaynak bulmadan üretilen ürünlerin tüketicilere ulaştırılmasına kadar olan süreci kapsadığı fikri oluşmaya başlamıştır. Tedarik zincirlerinin dijitalleşmeye başladığı son 10 yıla geldiğimizde ise son sanayi devriminin etkisiyle beraber tedarik zincirlerinde risk yönetimi, tersine lojistik, büyük veri analizi, yapay zekâ inovasyonu, nesnelere internetinin süreçlerde kullanılmaya başlanması ve son olarak robotik uygulamalar hayata geçerek tedarik zinciri yönetimi günlük hayatımızı ve sanayileri en çok etkileyen faktörlerin başında gelmesine neden olmuştur. Süreçlerin dijitalleşmesi, hızlı

veri akışı, veri depolanması ve işlenmesini olanaklı hale getirerek sürecin etkin ve verimli bir şekilde yürütülmesinde hayati rol oynamaktadır. Akıllı üretim sistemlerinin ve araçlarının gelişmesi üretim ve iş süreçlerinde köklü değişiklikler ortaya çıkararak tedarik zinciri alanında dijitalleşmeyi zorunlu kılmıştır (Büyüközkan ve Göçer, 2018). Bu gelişmeyle beraber işletmelerin rekabet edebilmeleri için dijital tedarik zincirlerine sahip olması gerekliliği artık kabul edilen bir gerçek olmuştur. Buna ek olarak dijitalleşme ve internet kullanımının kolaylaşarak her an kullanılmaya başlanması uzaktan eğitim olanağının gelişmesine neden olarak lojistik ve tedarik zinciri eğitimlerinin önemli bir parçası olmuştur. Alanda eğitimlerin artmasına paralel olarak tedarik zinciri yönetimi üzerine gerçekleştirilen çalışmalar çeşitlenerek gelişmeye başlamıştır. Eğitim içeriklerinin ve eğitim yollarının gelişmesi, yeni yaklaşımların ortaya konması ve dijitalleşme çağın etkisiyle beraber tedarik zincirleri artık esnek, çevik ve ileri düzeyde akıllı sistemler içermektedir (Rodrigue, 2020).

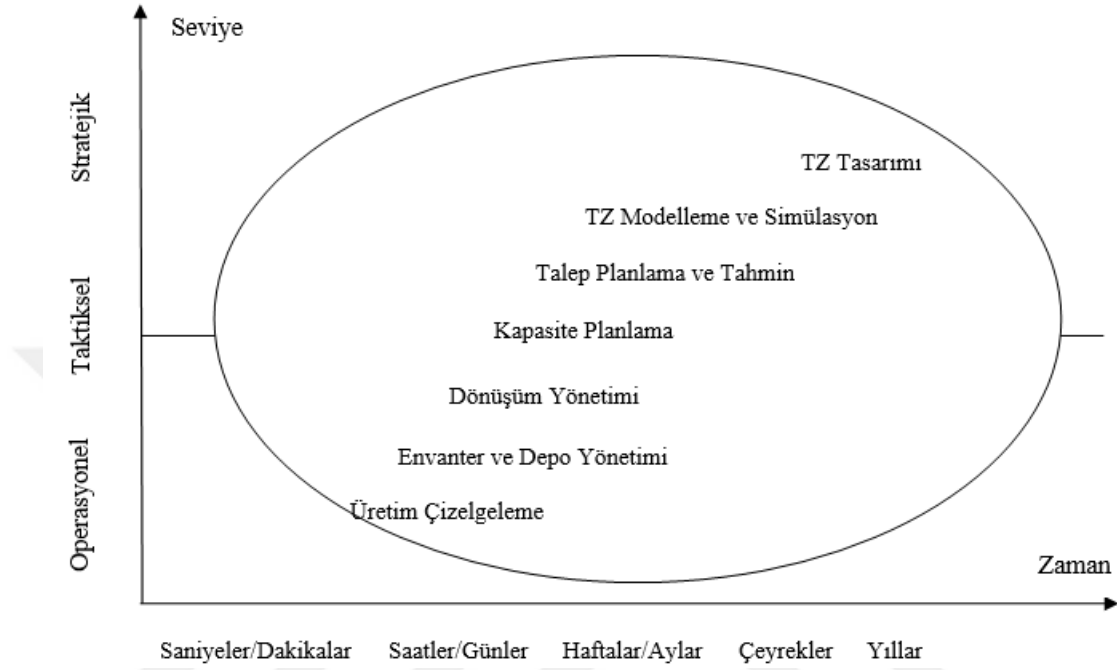
1.1.3. Tedarik Zinciri Yönetiminin Temel Fonksiyonları

Yirminci yüzyılın sonlarında işletme yöneticileri, sadece kaliteli ürün üretmenin rekabet gücü elde etmede önemli olmadığını; bunun yanında dış kaynak kullanımının ve tedarikçilerin işletme performansı ile müşteri taleplerini karşılama yeteneklerine doğrudan etki eden, maliyetlerin düşürülmesini sağlayan önemli bir faaliyet olduğunu görmüştür (Handfield ve Nichols, 1999).

Tedarik zinciri yönetiminde tasarlanan ağ içerisinde hammaddelerin temin edilmesinden başlayan süreç, bu hammaddelerin depolanması, üretim alanlarına iletilerek ürünlere dönüştürülmesi, ürünlerin depolanması, taşınması ve dağıtımını içeren geri dönüşüm mekanizmasına sahip bir şekilde işlemektedir.

Tedarik zinciri yönetimi (TZY) süreci içerisinde talep yönetimi, satın alma, üretim, stok yönetimi, taşıma, dağıtım ve iletişim teknolojilerinin kullanımı olmak üzere tedarik zincirinin bir takım fonksiyonları bulunmaktadır (Görçün, 2010). Tedarik zinciri yönetiminin sahip olduğu bu temel fonksiyonlar operasyonel, taktiksel ve stratejik olmak üzere üç temel seviyede toplanmıştır (Khoo ve Yin, 2003) ve birbiriyle iç içedir (Rusko vd., 2009). Tedarik zinciri yönetiminin fonksiyonlarının incelendiği bu üç seviyede hangi tür faaliyetlerin yapıldığının bilinmesi sınıflandırmanın

anlaşılabilirliği açısından önemlidir. Şekil 1. 1’de sunulan bu seviyeler, politikaların ayırt edilebildiği ve uygun kontrolün uygulanabildiği işlevdeki hiyerarşilerdir (Ballou, 1992).



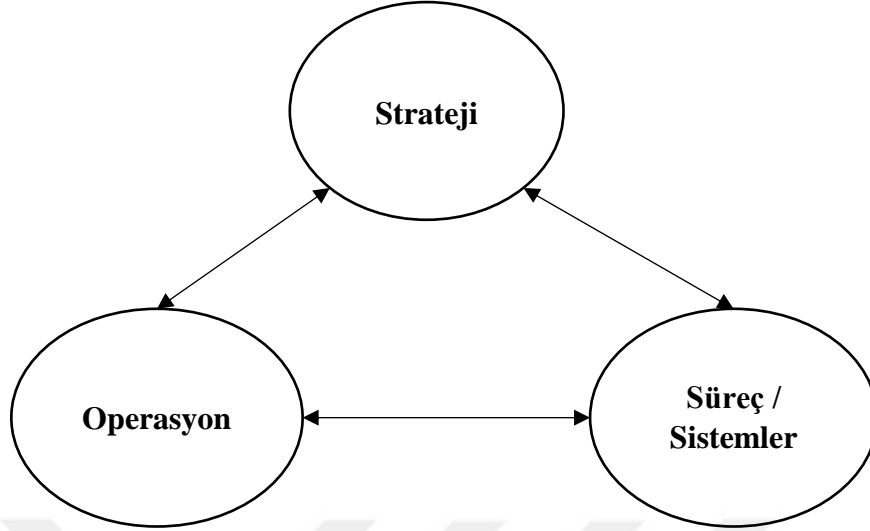
Şekil 1. 1. Tedarik Zinciri Yönetiminin Seviyeleri

Kaynak: Khoo ve Yin (2003)

Tedarik zincirlerinde stratejik düzey ölçütleri, üst düzey yönetim kararlarını etkiler ve çoğunlukla geniş tabanlı politikaların, kurumsal mali planların, rekabet edebilirliğin ve örgütsel hedeflere bağlılık düzeyinin araştırılmasını yansıtır (Gunasekaran vd., 2014). Zaman ufkunun en kısa olduğu (bir dakika, bir saat veya bir gün) TZY seviyesi operasyonel seviyedir. Bu seviyede envanter yönetimi, ambar yönetimi ve üretim çizelgeleme gibi işler yapılmaktadır. TZY’nde tasarım, modelleme ve simülasyon gibi aktivitelerin yer aldığı seviye olan stratejik seviyede zaman ufku birkaç hafta ile yıl arasındadır. TZY’nin taktiksel seviyesinde ise kapasite planlama ve ulaşım yönetimi yer almaktadır. Talep tahmini ve talep planlaması ise hem stratejik hem de taktiksel seviyede ki aktivitelerdir. Talep planlama ve talep tahmini hem stratejik seviyede hem de taktiksel seviyede yer alan aktivitelerdendir (Khoo ve Yin, 2003).

Tedarik zinciri yönetimine temel oluşturan birbiriyle sıkı bir etkileşim içerisinde bulunan bu üç boyut strateji, operasyon ve süreç/sistemler olarak ifade edilmiştir. Söz

konusu üç boyut ve temel gereklilikleri Şekil 1. 2’te gösterilmiştir:



Şekil 1. 2. Tedarik Zinciri Yönetiminde Anahtar Boyutlar

Kaynak: Spekman vd., 1999

Spekman vd. (1999) tarafından belirtilen anahtar boyutların gereklilikleri ise Tablo 1.1’de gösterilmiştir:

Tablo 1. 1. Tedarik Zinciri Yönetiminde Anahtar Boyutlar ve Gereklilikler

Tedarik Zinciri Yönetiminde Anahtar Boyutlar	Strateji	<ul style="list-style-type: none">• Stratejik kaynak yönetimi• Tedarikçi yönetimi• Tedarik hedefleri ve stratejiler• Uzun vadeli ilişkilerin kurulması• Uzun vadeli ortaklıkların kullanılması• Tedarik piyasası satın alma stratejileri
	Operasyon	<ul style="list-style-type: none">• Tedarikin organizasyon içindeki konumu - yeniden mühendislik• Satın almanın merkezileşme/yerelleşme derecesi• Tedarikin çapraz işlevsel etkinliği
	Süreç/İşlemler	<ul style="list-style-type: none">• Diğer temel tedarik zinciri süreçleriyle işlenen entegrasyon tedariki• Satın alma prosedürü, kontroller ve izleme sistemleri

Stratejik seviyede tesis konumlarını, üretim teknolojilerini ve tesis kapasitelerini belirleyerek, tedarikçiler ve müşteriler ile olan ulaşım kanallarına entegre bir tedarik zinciri ağı tasarlanmaktadır. Bu seviyede temel işgücü ve taşıma maliyetlerinin yanı sıra altyapı, vergiler ve pazarlara yakınlık gibi konular ele alınır. Ayrıca demonte

üretileen ürünlerin farklı müşteri taleplerine göre farklı tesislerde monte edilerek müşterilere ulaştırması da bu seviye kapsamında gerçekleştirilmektedir. Bu bakımdan tüm ağ içerisinde ulaşım kanalları etkin olarak planlanmakta ve işletilmelidir (Schmidt ve Wilhelm, 2000).

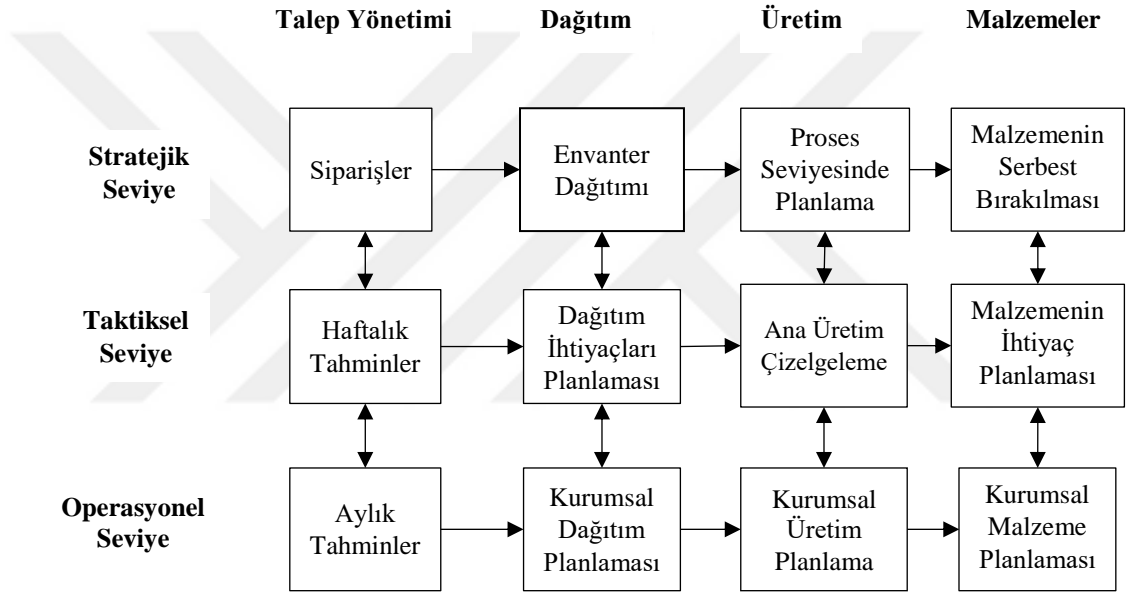
Stratejik düzeyde planlama, ağda kullanılacak tedarikçilerin, üretim tesislerinin ve distribütörlerin yerini, boyutunu ve optimal sayısını belirleyen tedarik zinciri ağ tasarımını içerir. Bu planlama aşaması, ağın düğümlerinin ve yaylarının ve bunların ilişkilerinin belirlenmesi olarak özetlenebilir. Stratejik düzeyde planlama, uzun vadeli planlamadır ve genellikle birkaç yılda bir, firmaların yeteneklerini genişletmesi gerektiğinde gerçekleştirilir. Birçok satıcı taktiksel ve operasyonel planlama düzeylerini desteklese de, görece az sayıda satıcı stratejik planlama yetenekleri sağlamaktadır. Bunun başlıca nedeni, büyük miktarda veri gereksinimi ve çeşitli niteliksel ve niceliksel faktörlerin dâhil edilmesini gerektiren bir tedarik zinciri ağ tasarlanmasının içerdiği karmaşıklıklardır (Talluri, 2000).

Taktik seviye, stratejik düzeyde belirlenen sonuçlara ulaşmak için ulaşılabilecek hedeflere karşı kaynak tahsisi ve performansın ölçülmesi ile ilgilidir. Bu düzeyde performans ölçümü, orta düzey yönetim kararları hakkında değerli geri bildirim sağlar (Gunasekaran vd., 2014). Taktik düzeyde planlama aşaması, öncelikle belirli bir ağ üzerinden mal ve hizmet akışının optimizasyonunu kapsayan planlamaları içermektedir. Bu seviyedeki kararlar, hangi ürünlerin hangi tesislerde hangi miktarda üretilmesi gerektiğini ve hangi tedarikçilerin hammadde ve alt bileşenleri tedarik etmesi gerektiğini içerir. Taktik düzeyde planlama, genellikle aylık bazda gerçekleştirilen orta vadeli planlamadır. Satıcı seçimini ve sistem satın alma sürecini karmaşıklaştıran, karar vericinin değerlendirmesi için bir dizi alternatif satıcının mevcut olduğu açıktır (Talluri, 2000).

Operasyonel düzeydeki ölçümler ve metrikler, doğru veriler gerektirir ve alt düzey yöneticilerin kararlarının sonuçlarını değerlendirir. Amirler ve işçiler, yerine getirildiği takdirde taktiksel hedeflere ulaşılmasına yol açacak operasyonel hedefler belirlemelidir (Gunasekaran vd., 2014). Operasyonel seviye, tedarik zincirinin verimli bir şekilde işletilmesi ile ilgili olan faaliyetleri kapsamaktadır. Bu seviyede ayrıntılı

sistemlere ve prosedürlere odaklanılmakta ve uygun kontrollerin ve performans ölçümlerinin yerinde olması amaçlanmaktadır. Genel olarak, işletmeler envanter yatırımı, servis seviyesi, hammadde etkinliği, tedarikçi performansı ve maliyetlere bu seviye kapsamında ölçmektedir (Stevens, 1990):

İşletmelerin sahip olduğu kendisine has tasarlanan tedarik zincirlerinin yönetiminde yer alan sipariş yönetimi, talep yönetimi, üretim, dağıtım, planlama ve stok yönetimi gibi fonksiyonlar bu üç seviyeye bağlı olarak işlemektedir. Söz konusu üç seviyede yer alan fonksiyonlar, birbiriyle ilişkileri ve içerdikleri faaliyetler Şekil 1.3'te gösterilmiştir (Çizmeci, 2002):



Şekil 1. 3. Tedarik Zinciri Yönetiminin Fonksiyonları

Şekil 1.3'te görüldüğü üzere tedarik zinciri yönetimini oluşturan üç seviyeye bağlı ve genellikle birbiriyle ilişkili toplam on iki tane fonksiyon bulunmaktadır. Tedarik zinciri yönetimini oluşturan bu fonksiyonlar genel başlıklarıyla şu şekildedir (Croxtton vd., 2001; Görçün, 2016).

- Talep ve sipariş yönetimi
- Planlama
- Stok yönetimi
- Depo yönetimi
- Sevkiyat
- İadeler

Tedarik zinciri yönetiminin fonksiyonları yapılan bazı çalışmalarda bu stratejik seviyelere bağlı olarak üretim, malzeme yönetimi ve iade yönetimi olmak üzere üç temel fonksiyon olarak ifade edilmiştir (Fox vd., 1993). Bu doğrultuda *üretim fonksiyonu* stratejik seviyede, yapılacak üretimin miktarının belirlendiği, taktik seviyede ise bu üretime dair girdilerin çizelgelendiği, operasyonel olarak ise üretimin çizelgelendiği faaliyetleri kapsamaktadır. *Malzeme yönetimi fonksiyonu*, stratejik seviyede üretime dair madde ve malzemelerin tedarik sürecini, taktiksel seviyede üretimin her aşamasında hangi madde ve malzemenin kullanılacağı ve operasyonel seviyede ise gereken bu madde ve malzemelerin temin edilerek alınması faaliyetlerini kapsamaktadır (Fox vd. 1993). Bu sınıflandırmaya göre son fonksiyon olan *iade yönetimi fonksiyonu* ise, hatalı ya da beklentileri karşılamayan ürünlerin geri bildirim mekanizması ile tekrar alınarak müşteri memnuniyetinin sağlandığı, hatalara dair çözüm yollarının arandığı verimliliğin artırılmasının ve sürekli iyileştirmenin sağlanmasına yönelik faaliyetleri içeren fonksiyondur (Rogers ve Lembke, 2001).

Günümüz iş dünyasında, müşterilerin talep, ihtiyaç ve siparişlerinin yönetimi oldukça hızla karşılanması gereken bir süreçtir. Müşterilerin beklentilerinin hızlı bir şekilde karşılanması için, işletmelerin tedarikçileri ile birlikte bir ağ içerisinde bütünleşmiş olması gerekmektedir. Bu doğrultuda her aşamadaki planlamaların bütünleştirilmiş bir yapıda olması gerekmektedir. İşletmelerin rekabetçi bir yapıda dinamik ve çevik olarak faaliyet göstermesi gerekmektedir. Söz konusu gerekliliği sağlamanın temel yollarından birisi etkin işleyen bir satın alma yönetimidir. İşletmelerde etkin olarak işleyen satın alma faaliyetleri, rakipleri karşısında bir kaldıraç etkisi rolü oynayarak işletmelere üstünlük sağlayacaktır. Bu bakımdan işletmelerin rekabet edebilmek için geliştirdiği satın alma stratejileri özel olarak tasarlanması gereken bir süreçtir (Benton, 2018).

Dijitalleşme çağını yaşadığımız günümüzde müşterilerden gelen taleplerin ya da siparişlerin, işletmelerin sahip olduğu tedarik zinciri ağı içerisinde oldukça hızlı ve doğru bir şekilde paylaşılması gerekmektedir. Bu yapı ile müşterilerin değişken talepleri karşılanabilecek, siparişe göre montajlar zamanında yapılabilecektir.

Belirtilen nedenlere ek olarak bazen üretim için gereken bir bileşeni satın almak daha düşük maliyetle gerçekleşeceği için daha avantajlıdır (Feng ve Lu, 2012).

Tedarik zinciri yönetimi açısından oldukça önemli olan satın alma fonksiyonu; üretim sürecinden gerekli olan bir bileşenin (hammadde ve yarı mamul gibi), işletmelerde geliştirilen tedarik stratejisine göre dışarıdan satın alınmasının kararlaştırıldığı; bu nedenle piyasada faaliyet gösteren potansiyel tedarikçilerin araştırıldığı, bunlar içerisinden en çok avantajlı olanın belirlendiği ve satın alma eyleminin gerçekleştirilmesi sürecini kapsamaktadır (Öztaş ve Uçan, 2002). Özellikle son dönemde yaşanan Covid-19 pandemisi ile çevrimiçi alışverişlerin ve ticaretin artması işletmelerin pazarlama faaliyetlerinin dijitalleşmesine neden olmuştur. Bu durum işletmelerin tedarik zincirlerini farklı bir boyuta getirmiştir. Artık oldukça farklı ürünler üretmek, bunları hızlı ve düşük maliyetli olarak tüketicilere sunmak zorunda kalan işletmelerin bu talebe cevap verebilmesi ağ içerisinde etkin bir satın alma süreci ile girdileri temin etmesine bağlıdır. Etkin bir şekilde satın alma sürecinin geliştirilmesi ise başarılı bir satın alma yönetimi süreci gerektirmektedir.

Tedarik zinciri yönetimi içerisinde satın alma faaliyetleri gerçekleştirilirken, ağ içerisinde bilgi akışının etkin olması yeni ürün geliştirme ve üretiminin planlanması içinde oldukça önemlidir. Etkin bir şekilde işleyen tedarik zinciri ağının bu bilgiler ışığında tedarik zincirinin fonksiyonlarını bütünleştiren bir yapıda olduğu açıktır. Bu yol ile müşterilerden çevrimiçi platformlar aracılığıyla alınan siparişler elektronik bağlantılar ile tüm sürece eş anlı olarak paylaşılmaktadır (Eymen, 2007). Tedarik zinciri ağ yapısı ve günümüz şartları incelendiğinde siparişlerin bu yönde etkin ve verimli bir şekilde yönetilmesi hayati bir öneme sahiptir.

Günümüzde işletmeler gerçekleştirmiş oldukları pazar araştırmaları ile ürettiklerin ürünlerin fiyatlarını, tedarik etmesi gereken bileşenlerin maliyetlerini, üretebilecekleri alternatif ürünleri araştırmaktadır. Bu faaliyetleri yaparken özellikle dışarıdan ürün ya da hizmet aldığı tedarikçileri derin araştırmalar içeren titiz çalışmalar sonucunda tespit etmektedir. İşletmelerin pazarlama fonksiyonunun tam tersi bir sürece sahip olan satın alma fonksiyonunda, satın alma yapılacak tedarikçinin belirlenmesinde söz konusu

tedarikçilerin performansını, itibarını, geçmişini ve maliyetleri değerlendirmektedir (Lambert ve Cooper, 2000).

Tedarik zincirinin bir diğer ana fonksiyonlarından olan talep yönetiminde, işletmeler faaliyet gösterdiği sektörden ve pazarlardan elde ettiği bilgileri en verimli şekilde ağ içerisinde paylaşarak bir üretim döngüsü oluşturmaktadır. Etkin bir şekilde işlemesi gereken talep yönetimi sayesinde, müşterilerin ve pazarların ihtiyaç duyduğu ürün ve hizmetler zamanında, niceliksel ve niteliksel olarak istenilen seviyede sunulabilecektir (Jüttner vd., 2007). Temel olarak tedarik zinciri yönetimi ile bir fonksiyonu olan talep yönetimi birbirinden ayrı yapılar olsa da belirtilen önemden dolayı oldukça iç içe ve birbirinin başarısını etkileyen yapılardır. Bu ilişki içerisinde talep fonksiyonu neyin satılması gerektiğine dair zaman, fiyat, miktar ve nitelik gibi bilgileri içerirken; tedarik zinciri bu bilgileri kullanarak satın alma eylemine dayanan bir üretim ağı oluşturmakta ve böylece talebin karşılanmasını sağlamaktadır. Müşterilerden ve pazarlardan elde edilen bilgilerin ve ihtiyaçların uygun maliyetli, istenen nitelikte ve zamanda üretilmesi ancak bu iki yapının kusursuz işleyen bir ilişkisine bağlıdır (Mentzer ve Moon, 2004).

Günümüzde artan rekabet şartları, pazarlara ve tüketicilere ait devasa veriler, oldukça çeşitli ürünler, teknolojinin üretimde uygulanması, çevrimiçi satışlar ile dünyanın herhangi bir yerine ürünlerin üretilmesi gibi şartlar altında işletmeler faaliyet göstermektedir. Tedarik zinciri açısından, bu değişikliklere adapte olabilen yapılar rekabet gücünü elde edecektir. Çünkü oldukça çeşitli siparişler ve talepler karşısında esnek ve çevik olmayan tedarik zincirleri taleplere cevap veremeyecektir. Çevik ve dinamik yapıda bir ağ tasarımı ile tedarik zincirleri talep yönetimi ile entegre edilerek faaliyetler düzenlenmelidir. Aksi takdirde işletmelerin müşterilerin bazen anlık oluşan taleplerine cevap verebilmeleri mümkün değildir.

İşletmeler, planlama fonksiyonlarının bir gereği olarak müşterilerinden gelen talepleri istenen nicelik ve nitelikte sunmak için etkin bir üretim planlaması yapmak zorundadır (Guide, 2000) Söz konusu planlama yapılırken mevcut olmayan ve üretimde gereken malzemeler süre, miktar ve maliyet bakımından belirlenerek tedarikçiler ile iletişime geçilmelidir. Bu yol ile sağlanan ve planlanan temin, üretim ve ulaştırma süreçleri

oluşturulan planlama ve akış şemaları dikkate alınarak takip edilmelidir. Bu yol ile gerçekleştirilecek süreçlerin daha başarılı sonuçlara ulaşılmasını sağlayacağı bir gerçektir (Lambert ve Stock, 1993).

Tedarik zincirlerinin anahtar fonksiyonlarından birisi de depo yönetimidir. Günümüz işletmelerinde genellikle depolar aynı zamanda bir dağıtım merkezi rolü oynamaktadır. Depo yönetiminde hammadde ve malzemelerin ürünlere dönüştürülmesi için üretim süreçlerine ve ardından üretilen ürünlerin müşterilere dağıtım faaliyetleri gerçekleştirilmektedir. Depo yönetimi gelen malları koordine etme, üretilen ve tedarikçilerden gelen malların depolanması, izlenmesi ve son olarak malların uygun varış noktalarına dağıtılması sürecini içermektedir. Depo yönetimi ile üretim tesisi, tüketiciler ve tedarikçiler günümüzde gelişen iletişim teknolojileri ile görünmez (kablesiz ya da sanal) hatlar ile bağlıdır. Modern rolü ile depolarda, gelen malzemeler konsolide edilmekte ve bunları uygun zamanda üretim tesisine dağıtılmaktadır (Harper, 2010).

Depo yönetiminde, mevcut stokların düşük maliyetle, dinamik ve esnek üretimi destekleyecek şekilde madde ve malzemelerin saklanması amaçlanmaktadır. Bu amaç için işletmelerde planlama, depolama, satın alma ve depo yönetimleri etkin ve birbiriyle iletişim halinde işletilmelidir. Ayrıca bu süreçte depolanacak maddelerin, malzemelerin ve ürünlerin kendilerine yapısal olarak uygun olan ortamlarda, gerektiğinde kullanılacak bir biçimde saklanması gerekmektedir. Bu hususlara dikkat edilerek oluşturulacak bir depo yönetimi maliyet avantajı sağlayacağı gibi hız ve esneklik avantajı da sağlayacaktır (Eymen, 2007).

Günümüzde artan rekabet ve özellikle tüketici taleplerindeki değişikliklerden kaynaklı çevik ve esnek bir yapıda tasarlanan tedarik zincirlerinin başarısında depo yönetimi fonksiyonu anahtar bir rol oynamaktadır. Müşterilerden gelen farklılaştırılmış ürünlerin monte edilmesi için düzenli ve etkin bir depo yönetimi gerekmektedir. Bir diğer taraftan hammaddelerin, ara mamullerin ve ürünlerin stok seviyelerinin etkin bir şekilde takip edilmesi gerekmektedir. Aynı zamanda üretilen ürünlerin dağıtım fonksiyonunu çerçevesinde müşterilere ya da pazarlara dağıtılmasında da depo yönetimi etkin, dinamik ve esnek olmalıdır. Diğer taraftan gereksiz stokların tutulması

da işletmeler için başlı başına bir maliyet kalemi olduğu için depo yönetimi bu bakımdan da önem arz eden bir fonksiyon olarak karşımıza çıkmaktadır.

İşletmelerin tedarik zincirlerinin etkin ve verimli bir şekilde yönetilerek başarıya ulaşılması, sahip olduğu fonksiyonların başarılı bir şekilde yürütülmesine bağlıdır. Esnek, dinamik ve çevik bir şekilde tasarlanan, ağ içerisinde ki birimler arasında koordinasyonun ve iletişimin etkin olduğu tedarik zincirleri maliyetlerin düşmesinden, müşteri taleplerinin karşılanmasına kadar işletmelerde anahtar bir rol oynamaktadır. Temel işletme fonksiyonlarının başarısı ve işletmelerin pazarlama faaliyetlerinin performansı, kar elde etmesi ve rekabet gücüne kavuşması tedarik zinciri yönetiminin bahsedilen fonksiyonlarının verimliliğine ve etkinliğine bağlıdır.

1.1.4. Tedarik Zinciri Yönetiminin Amaçları

Günümüzde modern bir yönetim felsefesi olarak ele alınan tedarik zinciri yönetiminde tüm süreç boyunca birçok karar alınmaktadır. Alınacak kararlar ve işletmelerin geliştirdiği stratejiler karşısında bazen dış kaynak kullanımı daha mantıklı ve avantajlı olmaktadır. Bu durum faaliyetlerin, süreç içerisindeki verimliliği ve akışı etkin kılacak şekilde tasarlanmasını gerektirmektedir. Tüm bu faaliyetlerin temel amacı, söz konusu işletmenin sürdürülebilirliğini ve karlılığının artırılmasının sağlanmasıdır. Bir başka ifadeyle tedarik zinciri yönetiminin temel amacı (Holten vd., 2002), aynı anda müşteri hizmetlerini en üst düzeye çıkararak tüketici ihtiyaçlarını en verimli şekilde karşılamak için entegre değer zincirlerinin tasarımı, işletilmesi ve bakımınıdır.

Tüketici ihtiyaçlarını anlamak ve karşılamak, müşterilere verilen değeri optimize etmenin ve tedarik zincirindeki tüm paydaşlara getiriye iyileştirmenin bir yolu olarak TZY'de büyük önem taşır (Mowat ve Collins, 2000). TZY'nin en temel amacı müşteri gereksinimlerine uymaktır ve TZY'nin en önemli iki yönünden biri de zincirin sonundaki müşterilere odaklanmasıdır (Taylor, 1997).

Zsidisin vd. (2000), tedarik zinciri yönetiminin temel amacını, işletmelerin tedarikçilerinden üretilen ürünlerin sunulduğu nihai satış noktasına kadar malzemelerin ve bilgilerin akışını etkin bir şekilde yönetmek olarak ifade etmiştir. Tedarik zincirinin amaçları ağ açısından ele alındığında; güncel ve doğru bilgilerin ağ

içerisinde iletilmesini sağlayarak, müşteri talepleri ile üretim arasındaki ilişkinin kusursuz hale getirilmesi ve bu yolla üretilen ürünlerin tüketicilere iletilmesidir (Cooper vd., 1997). Çünkü tedarik zinciri yönetimi aslında tüketicilerin istek ve beklentilerini tam zamanında üretim felsefesine göre karşılamak için geliştirilen bir süreçtir (Jayaraman ve Ross, 2003).

Tedarik zinciri yönetiminin bir diğer amacı, tedarik zinciri yönetimi içinde kalan her faaliyetin aynı amaçlara yönelik olarak faaliyet göstermesi, üretim ve dağıtımın en etkin ve verimli bir şekilde yürütülmesidir. Bundan dolayı, tedarik zincirini halkasında yer alan işletmeler birbirinden bağımsız faaliyetler olarak düşünülemez. Zincirdeki her bir üyenin performansı hem kendini hem de zincirdeki diğer faaliyet gösteren işletmeleri etkileyecek şekilde sıkı bir ilişki vardır. Etkin ve verimli işleyen tedarik zinciri yönetiminin amaçları şu şekilde derlenmiştir (Kehoe ve Boughton, 2001; Lee ve Kincade, 2003; Hollmann, 2011; Acar ve Köseoğlu, 2014):

- Maliyetlerin azaltılması,
- Ürün kalitesinin artırılması,
- Kaynak üretkenliğini maksimize etmek,
- Kârlılık durumunun yükseltilmesi,
- Rekabet gücünün yükseltilmesi,
- Standartlaştırılmış süreçler oluşturmak,
- İşletmenin değerinin yükseltilmesi,
- Pazardaki değişimlere karşı hassasiyetin oluşturulması,
- Pazar oranının artırılması,
- Ürünün çevrim zamanını kısaltmak,
- Üründeki hataları en aza indirmek,
- Müşteri hizmet performansının artırılması,
- Müşterilere cevap verme süresinde kısaltılmalar yapılması,
- Müşteri memnuniyetini arttırmak,
- Minimum envanter düzeyi sağlamak,
- Stokların azaltılması,
- Stok maliyetlerinin düşürülmesidir.

1.1.5. Tedarik Zinciri Yönetiminin Önemi

Dijital çağı yaşadığımız bu dönemde işletmeler, tüketici beklenti ve ihtiyaçlarının sürekli olarak değiştiği, oldukça fazla sayıda rakibinin olduğu küresel piyasalarda, yüksek teknolojinin kullanıldığı ve değişen ekonomik koşullar altında faaliyetlerini sürdürmektedir. Bu şartlar altında faaliyet gösteren işletmeler artık tedarik zincirlerini etkin kullanmak zorunda kalmıştır ve tedarik zincirlerini başlı başına bir süreç olarak ele alarak güvenilir, etkileşim içerisinde, etkin ve verimli zincirler oluşturmak için çalışmalar yapmaktadır (Halldorsson vd., 2007). Yapılan çalışmalar neticesinde işletmelerin tedarik zincirlerinin kendi bünyesinin dışında birçok işletmenin zinciriyle etkileşim halinde olan bir yapıda olduğunu ve geleneksel anlayıştan sıyrılmış modern bir yönetim felsefesi gerektirdiği ifade edilmiştir (Drucker, 1998). Artık dünya genelini ülke veya bölge fark etmeksizin etkileyen her şey, dalgalanan gaz fiyatlarından, çevresel kaygılara ve sağlık sorunlarına kadar yaşanan her bir gelişme ya da durum işletmelerin tedarik zinciri yönetimini etkilemektedir (Vergara vd., 2002).

Küreselleşme, teknolojik ve altyapısal gelişmeler, bilgi teknolojilerinin gelişmesi ve dış kaynak kullanımının daha optimal yapılmaya başlanması; ayrı ayrı faaliyetlere odaklanan işletmelerin bir araya gelerek bütünleşmiş bir sistem oluşturmasına neden olmuştur (Nikbakhsh, 2009). Dünya genelinde taşımacılığın gelişmesi, teknolojinin süreçlerde kullanılması ve tüketicilerin ulaşılabilirliğinin artması, covid-19 pandemisi gibi şartlar altında tedarik zinciri yönetimlerinin küresel olmasını, etkin ve kusursuz çalışmasını zorunlu kılmıştır. Bu zorunluluk altında başarılı faaliyetler gösterebilen zincirler tüketicilerin beklentilerini ve isteklerini gereken nicelik ve niteliklerde sağlamaktadır (Chandra ve Tumanyan, 2005). Birbirine entegre olmuş sanal bir ağ ile bağlanan bir zincire sahip işletmeler maliyetleri düşürme ve rekabet üstünlüğü sağlayarak faaliyet gösterme avantajına sahiptir (Kleab, 2017).

Günümüzde dünya, üretici ve tüketicilerin birbiriyle iletişim halinde olduğu, verilerin anlık tüm aktörlerce paylaşıldığı büyük bir tedarik zinciri olarak görülmektedir. Bu bakımdan artık işletmelerin sahip oldukları tedarik zinciri yönetimleri, çok uluslu şirketlerin büyümesi, ortaklıklar, küresel marka genişlemesi ve dış kaynak kullanımı gibi önemli konularla ilgilenir (Özal, 2011).

Tedarik zincirlerinin bu şekilde tasarlanması, ürün ya da hizmet sunan işletmeye avantajlar sağladığı gibi zincir içerisinde farklı aşamalarda yer alan her bir işletmenin başarısını ve karlılığını arttırmaktadır. Bu yapı sayesinde zincir ağı içinde yer alan her bir işletme aslında kendi sektöründe rekabet üstünlüğü sağlamış, rakipleriyle mücadele edebilen, faaliyetlerinin sürdürülebilirliğini sağlamış, karlılığını maksimize ve maliyetlerini minimize eden bir yapıya kavuşmuştur. Ayrıca zincirin herhangi bir aşamasında yapılan pazar analizi sonuçları tüm zincirle paylaşılmakta bu durumda kaynak planlamasından, inovasyon içeren ürünlerin üretilmesine kadar tüm süreçte kullanılmaktadır (Tutkun, 2007).

Tedarik zinciri yönetiminin son zamanlarda işletme faaliyetlerinin öneminin gün geçtikçe artmasının sebepleri arasında taşıma mesafeleri ve maliyetlerinin yükselmesi, üretim teknolojilerinin birçok alanda en son seviyeye ulaşması sonucu maliyeti düşürmek için tedarik zinciri yönetimi faaliyetlerine odaklanması gerekmektedir (Kobu, 2010). Bir başka ifade ile işletmeler kendi bünyelerinde bulunan tedarik kaynaklarını kullanmaktan çok, daha düşük maliyette kaliteli malzeme üreten ve kendi alanlarında daha çok uzmanlaşan tedarikçileri tercih etmektedir. (Lummus ve Vokurka, 1999).

1.1.6. Tedarik Zinciri Yönetiminin Faydaları

İşletmelerin sanal ağlarla birbirine bağlandığı, sürekli bilgi ve malzeme akışının olduğu; temel amacın müşteri beklentilerinin karşılandığı süreç olan tedarik zinciri yönetiminin sağladığı bir takım faydalar bulunmaktadır. Bu faydalar maddeler halinde şu şekildedir (Ross, 1997; Lambert vd., 1998; Lee ve Kincade, 2003; Fawcett vd., 2008):

- İki yönlü bilgi akışı sağlanır.
- İşletmeler süreç odaklı bir yapıya dönüşür.
- Ürün çeşitliliği sağlanır.
- Dış dünyaya daha az bağımlı olunur.
- Depolama ve taşıma maliyetleri düşürülür.
- Tüm maliyet kalemlerinde düşme gerçekleşir.
- İşletmeler yalın çalışma prensiplerine kavuşur.
- Teslimat performansı artar.

- Stoklar miktarı minimize edilir.
- Çevrim süreleri düşer.
- Daha doğru tahminler yapılır.
- Zincirin tamamında verimlilikte artar.
- Süreç içerisinde kapasite kullanım oranının maksimum seviyeye ulaşır.
- Karar destek sistemlerinin işlemlerine olanak tanır.
- Hammadde temini ve ürün sevkiyatı kolaylaşır.
- Küresel çalışma prensiplerine göre faaliyetler gösterilir.
- Tam zamanında üretim prensiplerinde bilgi paylaşımı sağlanır.
- Bilgiler tüm endüstriyle paylaşılır.
- Tedarik zincirlerinin performansı, tüm boyunca artar.

Günümüzde yaşanan dijitalleşme ve rakip firmaların sayısının artması işletmelerin maliyetlerinden, verimliliklerine ve ürün fiyatlarına kadar tüm süreci kontrol etmeleri zorunluluğunu ortaya çıkarmıştır. İşletmelerin kendi iş süreçlerinin yanında bir düğümünü oluşturduğu tedarik zincirinde, gerçekleştirilmesi gereken faaliyetleri de istenilen zamanda ve özelliklerde gerçekleştirilmesi gerekmektedir. Çünkü tedarik zinciri yönetimi içinde yer alan her bir işletme kendi başarısının yanında zincirinde başarısını gözetmelidir. Bu bakımdan tedarik zincirleri işletmeler açısından bir takım faydalar sağlamaktadır (Lambert vd., 1998):

- Ortak fayda,
- Uzmanlaşma,
- Uzun vadeli planlama,
- Daha düşük seviyeli stok,
- Belirsizliklerin ortadan kalması.

Tedarik zinciri yönetiminin bahsedilen faydalarının bir kısmı işletmeler, bir kısmı müşteriler ve bir kısmı da tedarikçilere yöneliktir. Söz konusu faydalar bu gruplara göre müşteriye, işletmeye ve tedarikçiye sağladığı faydalar olarak sınıflandırılmaktadır (Bakoğlu ve Yılmaz, 2001):

- Müşterilere Sağladığı Faydalar;
 - Ürün bulmak kolaylaşır.

- Stok yatırımlarına yönelik riskler azalır.
- Maliyetler azalır.
- İşletmeye Sağladığı Faydalar;
 - İşletme karlılığı yükselir.
 - İşletme sermayesine olan ihtiyaç azalır.
 - Ürün çevrim süreleri oldukça azalır.
 - Esnek üretim mümkün olur.
 - Siparişler zamanında teslim edilebilir.
 - İadeler ve bilgi akışı sayesinde süreç iyileştirmesi ve kalite sağlanabilir.
 - Minimum stok tutulur ve bu nedenle stok maliyetleri azalabilir.
- Tedarikçilere Sağladığı Faydalar;
 - Satışlar artar.
 - Rekabet gücü yükselir.
 - Satışların gidişatı ağ içerisinde bilgi akışı ile sağlanarak avantaj sağlar.

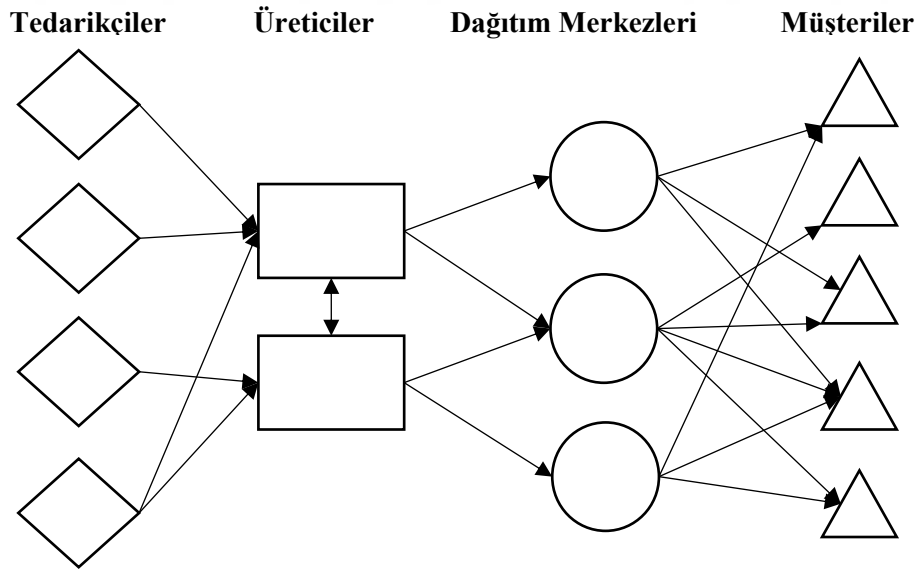
1.1.7. Tedarik Zinciri Ağ Tasarımı

Tedarik zinciri geleneksel anlamda; tedarikçiler, imalatçılar, dağıtıcılar, toptancılar, perakendeciler gibi çeşitli iş aktörlerinden oluşan bir ağıdır. Bu ağda gereken hammaddelerin sağlanmasından ürünlerin pazarlara ve müşterilere iletilmesine kadar yapılacak tüm faaliyetler bir arada yürütülür. Bu sayede tedarik zincirleri, malzemelerin, bilgilerin ve ürünlerin aktarıldığı bütünleşmiş bir süreç oluşturmaktadır (Chopra vd., 2007). Klasik bir zincirde, tedarikçilerden elde edilen hammadde ve malzemeler üretim alanlarında mamüllere dönüştürülür, dönüştürülen bu mamüller depolanır ve gerektiğinde müşterilere iletilir (Simchi-Levi vd. 2009). Dijitalleşmenin etkisiyle tedarik zincirleri, işletmelerin başarısına etkisi ve ürünlere erişimin kolay olmasında önemli bir rol oynamaktadır (Narasimhan ve Narayanan, 2013).

Tedarik zinciri yönetiminde yer alan her bir aktörün kendisine has görevleri bulunmaktadır (Hugos, 2018):

1. **Üreticiler:** Hammadde ve malzemeleri ürünlere dönüştüren birimlerdir. Üreticiler, hammadde temininden mamül iletilmesine kadar olan süreçteki tüm faaliyetleri gerçekleştirir.

2. **Dağıtıcılar:** Üreticilerin üretim alanlarında ortaya koymuş olduğu mamülleri toptancı, perakendeci ya da doğrudan müşteriye ileten birimlerdir. Zaman ve yer unsurunu barındıran bir faaliyet yelpazesine sahip olan dağıtıcılar hammaddeleri ve ürünleri uygun şartlarda depolayarak ihtiyaç duyulan aktöre iletmekle sorumludur.
3. **Perakendeciler:** Üretilen ürünleri dağıtıcılar aracılığıyla alan depolayan ve tüketicilere küçük parçalar halinde satan birimlerdir. Perakendeciler tüketicilere en yakın olan aktör olduğu için, pazarların ihtiyaç ve beklentileri ile pazarlarda yaşanan değişimleri ilk tespit eden aktördür. Bu bakımdan zincirin devam eden süreçte başarısı bir noktada perakendecilere bağlıdır.
4. **Müşteriler:** Müşteriler ya da tüketiciler, zincir içerisinde üretilen mamülleri satın alan, onun özelliklerini belirleyen bireylerdir.
5. **Hizmet sağlayıcılar:** Zincir içerisinde yer alan diğer aktörlere hizmet sunan aktörlerdir. Hizmetlerin birbirine kusursuz bağlanması, akışın sağlanması ve zincirin etkinliğini doğrudan etkilemektedir. Hizmet sağlayıcılara nakliyeciler, depolama kuruluşları ve finans şirketleri örnek verilebilir.



Şekil 1. 4. Genel Tedarik Zinciri Ağ Yapısı

Kaynak: Melo vd. (2007)

Bir işletmenin tedarik zinciri, ürünü kaynaktan nihai tüketim noktasına taşımaya izin verir. Büyük perakendecilerden ileri teknoloji elektronik üreticilerine kadar dünyanın

dört bir yanındaki lider firmalar, tedarik zincirlerini stratejik bir silah olarak kullanmayı öğrendiler. Tedarik zinciri, tedarikçiler, fabrikalar, depolar ve her bir ürünün menşeyinden nihai müşteriye kadar olan ürün akışları tarafından tanımlanır. Bu tesislerin sayısı ve konumu, herhangi bir tedarik zincirinin başarısında kritik bir faktördür. Aslında bazı uzmanlar, tedarik zinciri maliyetlerinin %80'inin tesislerin konumu ve aralarındaki optimum ürün akışının belirlenmesi ile bağlantılı olduğunu öne sürmektedir. En başarılı şirketler bunu kabul eder ve en iyi tesis konumlarını ve ürün akışlarını belirleyerek stratejik planlamaya önemli bir önem verir. Tesislerin optimal konumu ve boyutunu ve tesislerdeki akışı belirlemek için kullanılan disipline tedarik zinciri ağ tasarımı denir (Eskandarpour vd., 2015).

Bir şirketin temel hedefi, tedarik zincirinden geçen ürünlere bir değer katmak ve bu ürünlerin; istenilen miktarlarda, uygun nitelikte ve istenilen zamanda nakliyat sürecinde rekabetçi bir maliyet anlayışıyla dağıtılması sürecidir (Paksoy, 2005). Bir tedarik zinciri, iki ana iş sürecinden oluşmaktadır (Min ve Zhou, 2002):

- Malzeme Yönetimi (Gelen Lojistik)
- Fiziksel Dağıtım (Giden Lojistik)

Ağ kesintileri, miktarını belirlemesi zor olsa da tedarik zincirinin performansı için çok önemli olan tedarik belirsizliğine yol açar. Tüm tedarik zinciri ağları ve lojistik sistemleri, günümüzde periyodik olarak bu tür aksaklıklara maruz kalmaktadır. Bununla birlikte, tesis yeri ve tasarımı, envanter ve üretim planlaması ve ayrıntılı çizelgeleme üzerine yapılan geçmiş araştırmaların çoğu, bu tür aksaklıklara fazla ilgi göstermemiştir. Melo vd. (2009), tedarik zinciri tasarım literatürünün büyük çoğunluğunun işletme maliyetini (OC) en aza indirme veya kârı en üst düzeye çıkarma ile ilgili olduğunu göstermektedir. Kesintilere maruz kalan sağlam tedarik zincirleri tasarlamaya yönelik araştırmalar, ancak son zamanlarda önemli ölçüde ilgi gördü (Shukla vd. 2011).

Hem talep hem de arz belirsizliği tatminsiz müşterilere yol açar, ancak literatürün çoğu talep belirsizliğinin tedarik zinciri performansı üzerindeki etkisine odaklanmıştır. Talep belirsizliği alanındaki çalışmaların çoğu, sırasıyla beklenen ve en kötü durum senaryolarını planlayan stokastik ve sağlam optimizasyon yöntemlerine

odaklanmaktadır. Hendricks ve Singhal (2003), tedarik zinciri aksaklıklarının hissedar serveti üzerindeki etkisini inceliyor. Tedarik zinciri aksaklık duyurularının hissedar değerinde yüzde 10,28'lik anormal bir düşüşle ilişkili olduğunu buldular. Ayrıca, yüksek büyüme potansiyeline sahip küçük firmaların, büyük firmalara kıyasla daha olumsuz bir tepkiyle karşılaştıklarını ve dolayısıyla tedarik zinciri tasarımında risk yönetiminin önemini altını çizdiklerini bulmuşlardır (Shukla vd. 2011).

Ağ tasarım problemi, tüm tedarik zincirinin uzun vadeli verimli çalışması için optimize edilmesi gereken en kapsamlı stratejik karar problemlerinden biridir. Kullanılacak fabrika, depo ve dağıtım merkezlerinin sayısını, yerini, kapasitesini ve türünü belirler. Aynı zamanda dağıtım kanalları ve tüketilecek, üretilecek ve tedarikçilerden müşterilere gönderilecek malzeme ve ürün miktarlarını da kurar. TZY ağ tasarım problemleri, basit tek ürün tipinden karmaşık çoklu ürün tipine ve doğrusal deterministik modellerden karmaşık doğrusal olmayan stokastik modellere kadar geniş bir formülasyon yelpazesini kapsar (Altıparmak vd. 2006).

Tedarik zinciri ağ tasarımı problemleri üç şekilde ele alınabilir. İleri yönlü, tersine ve kapalı döngü ağ tasarımlarıdır. Bu kapsamda tam bir sürdürülebilirliğin sağlanabilmesi için kapalı döngü tedarik zinciri ağ tasarım modelleri ilgi görmektedir (Lundin, 2012).

- ***Tedarik Zincirinin İleriye Doğru Yönlendirilmesi:*** İleriye doğru TZAT malzeme, tedarikçiden tesise akar ve daha sonra müşteriye ulaşır. Bu modelde depo ve dağıtıcıları içerebilen birçok aşama vardır (Arumugham vd., 2017).
- ***Tedarik Zinciri Ağının Tersine Yönlendirilmesi:*** “Ürün geri çağırma ve garanti ve satış sonrası hizmet, yaşam sürelerini tamamlamaları, kullanım olanağı kalmamış ya da kalitesizlik gibi nedenlerle iade edilen ürünlerin, tüketim noktalarından toplanması, test edilmesi ve bu ürünlere değer katılarak yeniden ekonomiye kazandırılması çalışmalarını içermektedir” (Erol vd., 2006).
- ***Kapalı Döngü Tipi Tedarik Zinciri Ağı:*** Kapalı döngü tedarik zincirleri, geleneksel ileri ürün akışı ve ileri tedarik zinciri faaliyetlerine ek olarak tersine akış ve tersine tedarik zinciri faaliyetlerini de içeren tedarik zincirleridir. (Guide vd., 2003)

Kapalı döngü tedarik zinciri, ileri yönlü akış ve ileri tedarik zinciri faaliyetlerine ilaveten tersine akış ve tersine tedarik zinciri faaliyetlerini de içeren tam bir döngüyü sağlayan tedarik zincirleridir (Krikke vd., 2004). İleri yönlü tedarik zincirlerinin genel yapısı hammaddeden nihai ürün elde edilmesine ve son tüketiciye ulaştırılması süreç ve faaliyetlerini içerirken, tersine tedarik zinciri ise ürünlerin son tüketiciden toplanıp atık tesislerine iletilmesi ve bu tesislerde ilgili aşamalardan geçerek ayrıştırılıp ekonomiklik, çevresel koşullar dikkate alınarak yeniden döngüye en uygun şekilde katkı sağlaması çalışmalarını içermektedir. Toplanan ürünler yeniden döngüye katılırken hammaddelerine ayrıştırılıp üretim tesislerine gönderilebilir, yenilenme tamir bakım faaliyetleriyle ikinci el piyasa satışlarına verilebilir ya da belli bir maliyete katlanılarak çevreye en az zarar ile bertaraf işlemine tabi tutulur (Kaya ve Alatur, 2017).

Tedarik zinciri ağ yapısının tasarımı yapılırken dikkat edilmesi gereken boyutlar Lambert vd. (1998) tarafından aşağıdaki şekilde belirlenmiştir:

- Tedarik zincirinin üyelerinin belirlenmesi:
- Tedarik zinciri ağ yapısının boyutu:
- Üyeler arasındaki bağlantı tipi:

1.1.8. IoT Tabanlı Tedarik Zinciri Yönetimi

Tedarik zinciri yönetimi uygulamada oldukça eski bir disiplindir ancak kavram olarak ilk kez yirminci yüzyılda ifade edilmiştir. Başlarda oldukça basit bir şekilde, tek hatlı olarak düşünülen tedarik zincirleri, hammadde sağlayıcılardan tüketiciye doğru bir yapıdadır. Tarihsel süreç içerisinde teknolojinin, taşımacılığın ve üretim alanlarının gelişmesi ile beraber tüketici ihtiyaçlarında yaşanan değişimler gibi faktörlerin etkisiyle tedarik zincirleri basit bir hat şeklinden; birden fazla hammadde sağlayıcının, birden fazla üretim alanının ve çok çeşitli pazarlara iletilen, farklı dağıtım kanalları içerebilen gelişmiş bir ağ halini almıştır. Ancak yaşanan bu gelişim ve değişim ile birlikte yirmi birinci yüzyılda hayatımıza giren dijital dönüşümle beraber artık dijital tedarik zincirlerinin varlığından bahsedilmektedir. 2011 yılında son sanayi devriminin ilan edilmesi ile birlikte resmen hayatımıza giren ve tedarik zinciri alanında yüksek teknoloji içeren bileşenlerin kullanılmasını olanaklı kılan bir çağ yaşamaktayız. Dijital çağ içerisinde işletmeler için en önemli faaliyet alanlarından birisi tedarik zinciri

yönetimleridir. Artık hayatımızın her alanında olduğu gibi tedarik zinciri yönetiminde de internet, yapay zekâ ve sensörler kullanılarak faaliyetler planlanmakta, koordine edilmekte ve gerçekleştirilmektedir.

Bu başlık altında IoT tabanlı ya da dijital tedarik zinciri kavramı detaylı olarak açıklanacaktır. Çalışmanın uygulama kısmının ve amacının anlaşılabilmesi için konunun bilinmesi önemlidir.

Son sanayi devriminin getirdiği yeniliklerin tedarik zinciri yönetiminde uygulanması ile birlikte tüm ağ birer büyük veri kaynağı haline gelmiştir. Tedarik zinciri ağı içerisinde üretilen devasa verilerin depolanması, saklanması, ayrıştırılması ve işlenerek analiz edilmesi tedarik zinciri yöneticilerinin ana odak noktası haline gelmiştir. Elde edilen büyük veriler üzerinde bu işlemlerin yapılabilmesi ise klasik metotların aksine gelişmiş teknoloji kullanımı gerektiren yapay zekâ tabanlı sistemler ile olmaktadır. Bu uygulamalar IoT tabanlı tedarik zincirlerini geleneksel yapıdan farklılaştırmaktadır. Artık klasik tedarik zincirlerine kıyasla daha düşük maliyetli, daha hızlı ve belirsizliklerin minimize edildiği ağlar tasarlanmaktadır. Bu tez çalışması kapsamında uygulama metodolojisi olarak belirlenen makine öğrenmesi de tasarlanan yeni ve dijital ağ içerisinde üretilerek aşamalar arasında paylaşılan büyük veriyi analiz etmede en yaygın kullanılan teknikleri içermektedir. Makine öğrenmesi teknikleri ile bilgisayarlar ile yapılan analizlerin güvenilir veriler ile doğru yapılması ve sonuçların işe yarar hale getirilmesi tedarik zinciri yönetimi için oldukça önemli bir konu haline gelmiştir.

On sekizinci yüzyılın sonlarında buharlı makinelerin icat edilmesiyle ortaya çıkan ilk sanayi devriminden son sanayi devrimine doğru zaman içerisinde gelindiğinde; atölye tipi üretimden seri üretime geçilmesi, üretimde bantların kullanılması, otomasyon gibi gelişmeler yaşanmıştır. Yaşanan bu gelişmeler son sanayi devrimine kadar genellikle üretim alanında olmuştur. Ancak günümüzde halen etkisini devam ettiren son sanayi devrimi temel olarak dijital çağa girmemize sebep olan gelişmeleri ortaya çıkarmış ve yalnızca üretimi değil birçok alanı etkilemiştir (Hofmann ve Rusch, 2017). Endüstri 4.0 olarak adlandırılan bu sanayi devrimi ile birlikte artırılmış gerçeklik, bulut bilişim, büyük veri, sensörler ve nesnelerin interneti gibi yenilikler gerek üretim alanlarına

gerekse de diğ er alanlarda hızla kullanılmaya başlanmıştır (Radivojević & Milosavljević, 2019). Dijitalleşme, bu anlamda tedarik zincirleri içerisinde entegrasyonu sağlayarak maliyetleri düşüren önemli bir gelişme olarak alana yansımıştır (Raj vd., 2014). Endüstri 4.0 ile birlikte üretim alanları, klasik yapıdan çıkarak; bahsedilen bileşenlerin entegre edilmesiyle akıllı fabrikalar; tedarik zincirlerine entegre edilmesi ile beraber ise akıllı ya da dijital tedarik zincirleri ortaya çıkmıştır.

Geleneksel tedarik zinciri yaklaşımının bir takım eksik özellikleri bulunmaktadır. Sahip olduğu bu eksikliklerden dolayı tedarik zincirleri günümüz şartlarında yetersiz kalmaktadır. Çünkü günümüzde etkin bir yapı oluşturması için tedarik zincirlerinin hem bu ana hem de gelecek dönemlere dair beklenti ve talepleri karşılar bir yapıda olması gerekmektedir (Akben ve Avşar, 2017). İşletmelerde dijitalleşmeden bu anlamda en fazla etkilenen disiplinlerin başında tedarik zincirleri ve alt bileşenleri olan lojistik faaliyetleri bulunmaktadır. Dijital tedarik zincirlerinde planlanan faaliyetler gerçekleştirilirken, tedarik zinciri ağı içerisindeki hammadde, malzeme, ürün ve kullanılan ekipmanların sürece ve makinelere entegre edilmiş sensörler ile kendi aralarında optimum bir şekilde organize edilmiş bir sanal bağlantı vardır (Luthra ve Mangla, 2018). Bu sanal bağlantı ile bilgi akışı eş zamanlı ve hızlı bir şekilde iletilmektedir. Tüketici tercihlerinde yaşanan ani değişiklikler, üretimde yaşanan problemler gibi hızlı gelişen durumlar karşısında tedarik zincirleri bu yapı sayesinde dirençli ve esnek bir yapıya kavuşmaktadır. Yine bu yapı sayesinde kontrol mekanizmalarının da etkin işleyeceği bir gerçektir.

Dijitalleşme ve endüstri 4.0 bileşenlerinin süreçlere dâhil edilmesi işletmeleri tedarik zinciri konusunda geleneksel yapıdan uzaklaşarak; sadece malzeme ve ürünlerin akışını ve taşınmasını ifade eden klasik bir anlamdan uzaklaştırarak yeni bir bakış açısı geliştirmeye zorunlu kılmaktadır. Tedarik zinciri ağı içerisinde ki veri akışının olması ve iletişimin etkisiyle birbirinden ayrı olarak planlanan depolama ve taşıma işlemleri artık bir arada düşünülen, karmaşık bir ağ yapısı ortaya çıkarmaktadır (Büyüközkan ve Göçer, 2018). Teknolojide meydana gelen gelişmeler ve dijitalleşmenin tedarik zinciri yönetimine entegre edilmesiyle, bahsedilen yeni ağ yapısını ortaya çıkaran disiplin olarak dijital tedarik zinciri yönetimi karşımıza çıkmaktadır.

Geleneksel tedarik zincirleri dijitalleşirken, klasik yapıda ayrı ayrı olan adımlar bir sarmal haline gelerek birbiriyle entegre bir yapı oluşturur (Yıldız, 2018):

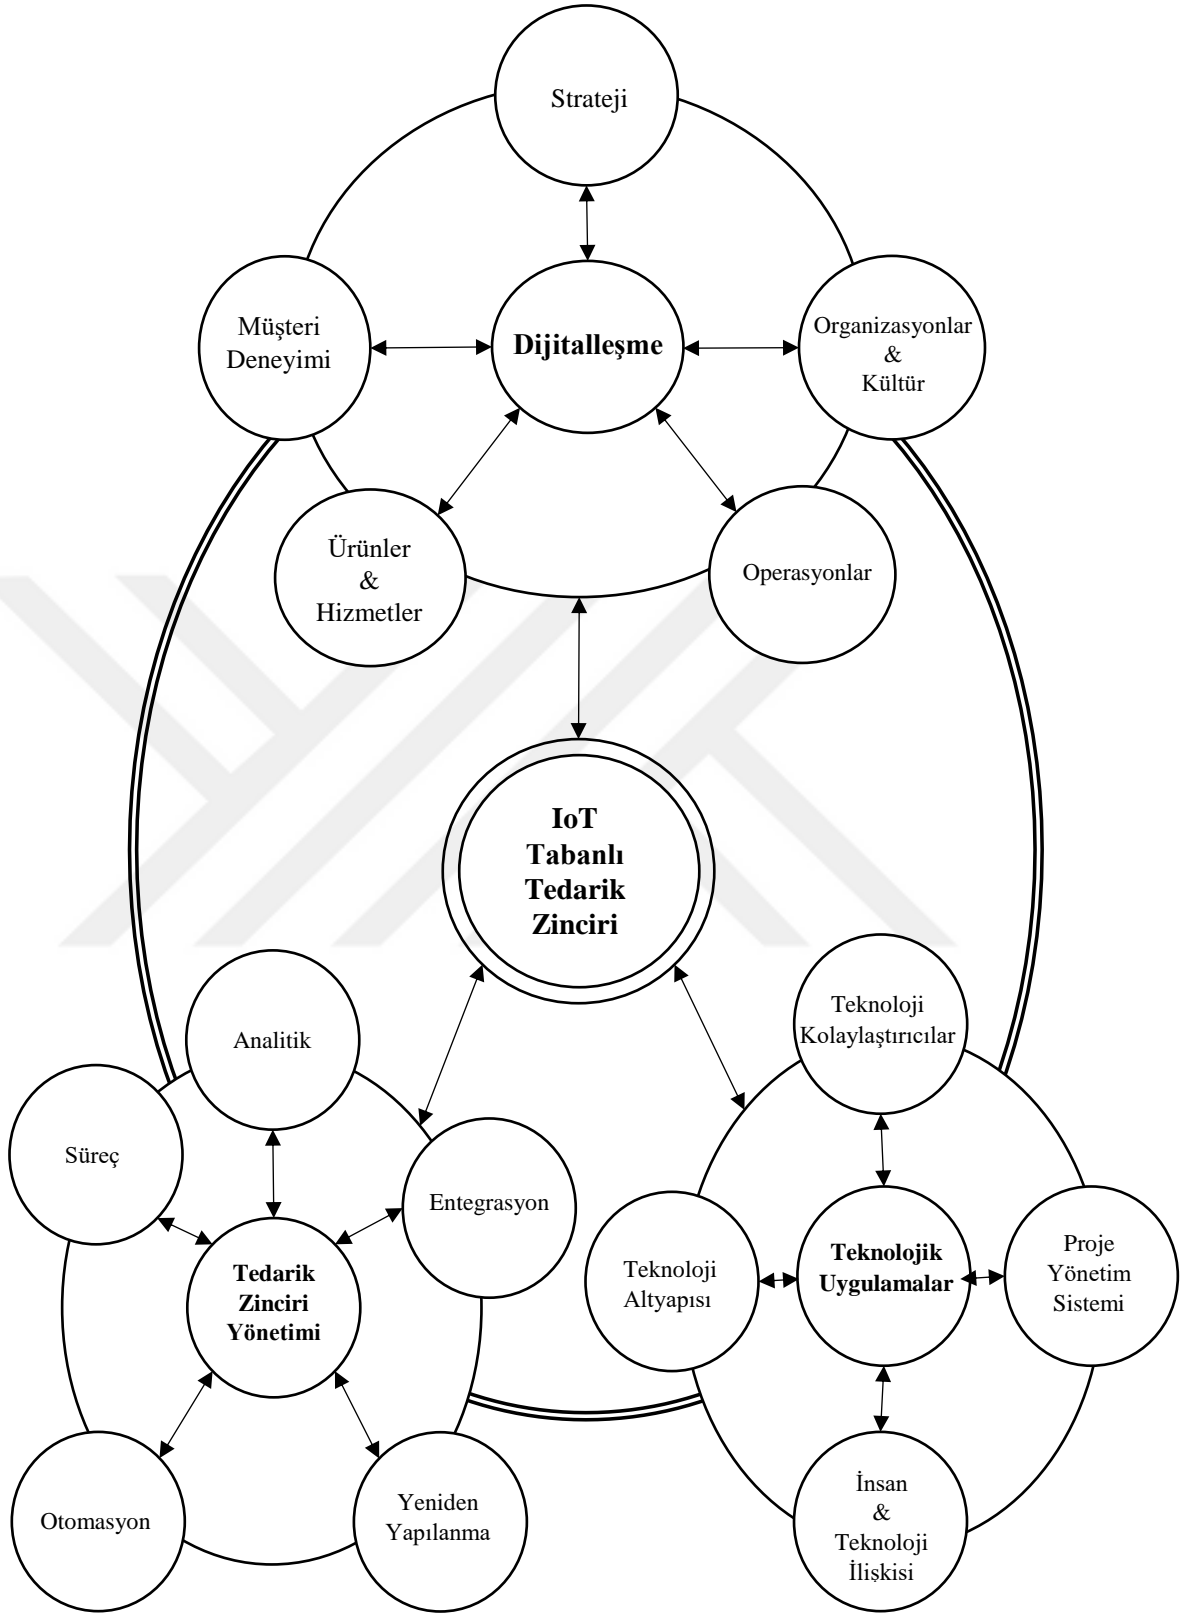


Şekil 1. 5. Geleneksel Tedarik Zincirinin IoT Tabanlı Tedarik Zincirine Dönüşümü

Kaynak: Yıldız, 2018

Şekil 1.5'te belirtildiği gibi geleneksel tedarik zincirlerinin türleri olan yetenek, fiziksel tedarik, bilgi ve finansal tedarik zinciri dallarının tamamını; sosyal medya, mobil iletişim, büyük veri ve bulut bilişim ile bütünleştirerek birbirine entegre tek bir yapı haline getiren disiplin dijital tedarik zinciri olarak isimlendirilmektedir.

Nesnelerin internetine dayanan ve dijitalleşen bir tedarik zincirini oluşturan disiplinler ve içerikleri aşağıdaki şekilde verilmiştir:



Şekil 1. 6. IoT Tabanlı Tedarik Zincirini Oluşturan Disiplinler ve Bileşenleri

Kaynak: Büyüközkan ve Göçer (2018)

Şekil 1.6'dan görüldüğü üzere IoT tabanlı tedarik zinciri dijitalleşme, tedarik zinciri yönetimi ve teknolojik uygulamalar olmak üzere üç disiplinin bir araya gelerek oluşturduğu; bu disiplinlerin birbirinden ayrı olarak sahip olduğu otomasyon, analitik, entegrasyon, teknolojik altyapı, insan-teknoloji ilişkisi, müşteri deneyimi, strateji ve ürün ile hizmetler gibi bileşenlerin tamamına tek başına sahip olan; ileri teknolojik uygulamalara sahip bir disiplindir.

Son sanayi devrimi ile birlikte tedarik zinciri konusunda birçok önemli gelişme olmuştur. Dijital çağ ile beraber zincir içi iletişimler gerçek ortamlardan sanal ortamlara taşınarak dijital iletişime dönüştür (McIvor ve Humphreys, 2004). Yaşanan bu gelişmeler ile birlikte tedarik zinciri yöneticilerinin sahip olduğu sürece dair bilgi miktarı artmıştır. Zincir içerisinde kullanılan yeni teknolojiler, tedarik zincirlerinin ağ içerisinde yer alan tüm üyelere gerçek ve eş zamanlı olarak veriler sağlayan esnek bir yapı haline gelmesine neden olmuştur (Cavalcante vd., 2019). IoT tabanlı tedarik zinciri yönetimi bir başka ifade ile birbirinden ayrı olan uygulamaların ve farklı tesislerin tedarik zinciri ağı boyunca sistematik bir biçimde birbirine sanal ağlar ile bağlandığı yapıdır (Abdel-Basset vd., 2018). Esnek bir yapı haline gelen ve dinamik forma dönüşen tedarik zincirlerinde, ağ içerisinde yaşanan problemler ve iş akışları oldukça karmaşık bir hale gelmiştir. Dünya çapında faaliyet gösteren şirketler bile artık yazılımsal olarak birbirine bağlı ve eş zamanlı bilgi akışının olduğu, farklı yerler arasında üretilen, satılan ve depolanan ürünlere dair bilgilerin paylaşıldığı dijital bir zincir haline gelmiştir (Bhargava vd., 2013). İleri teknoloji kullanılmaya başlanmasıyla birlikte hammaddelerin taşıma yollarının gelişmesi, dünyanın herhangi bir yerine ürünler gönderilmesi, internet üzerinden satışlar alanı ulusal bazdan küresel bir yapıya dönüştürmüştür. Çevrimiçi olarak tüketicilerin ürünler satın alması, gelişen teknolojik araçların tedarik zinciri ağı içerisine entegre edilmesi, sürekli olarak sağlanan büyük veri analizi işletmeleri zincirler üzerinde büyük veri analitiği yapmaya zorunlu kılmıştır (Hung ve Hsieh, 2017). Yaşanan bu zorunluluk ile beraber geleneksel tedarik zinciri yönetiminden IoT tabanlı tedarik zincirine doğru bir evrim hızlı bir şekilde olmuş; bu anlamda yapılacak analizler ve büyük veri kullanımı işletmeler için sürdürülebilir değer yaratan ve aynı sektörde faaliyet gösteren işletmelere karşı önemli bir rekabet avantajı sağlayan önemli bir süreç haline gelmiştir.

Klasik tedarik zincirlerinin dönüşüme uğramasından dolayı yaşanan değişim tedarik zincirinin taşıdığı anlam üzerinde de değişime neden olmuştur. Artık tedarik zinciri yerine IoT tabanlı ya da dijital tedarik zincirleri olarak ifade edilmeye başlamıştır. Günümüzde oldukça sık olarak tartışılan IoT tabanlı tedarik zinciri yönetimi ve optimizasyonu klasik yönetim anlayışlarının dışında yeni yönetim anlayışları da geliştirmeyi zorunlu kılmaktadır (Büyüközkan ve Göçer, 2018). Bu bakımdan IoT tabanlı tedarik zinciri, sürdürülebilir bir performans sağlama amacıyla zincir içerisine gelişmiş bilgi teknolojilerinin entegre edilerek çevik bir yapıya dönüştürüldüğü, kullanılan yeni teknolojiler (arıtılmış gerçeklik, büyük veri, sensörler gibi) ile birlikte müşteri ihtiyaçlarına yönelik faaliyetler gerçekleştirilen, maliyetleri düşürerek daha fazla katma değer sağlayan bir süreç olarak ifade edilmektedir (Ageron vd., 2020). IoT tabanlı tedarik zincirleri ile birlikte artık merkezi yönetim anlayışı ortadan kalkması, yeni iş modellerinin geliştirilmesi, internet tabanlı network ağlarının tasarlanması ve bulut bilişim sistemlerinin kullanılması zorunlu bir hale gelmiştir (Özarı ve Arslan, 2018).

IoT tabanlı tedarik zincirleri içerisinde bağlantıların kablolar yerine internet tabanlı sistemlerle çevrimiçi olarak gerçekleştirilmesi, tüm bilgilerin eş zamanlı ve düşük maliyetle iletilmesini ve depolanmasını sağlamaktadır. Bilgilerin teknoloji ile bu şekilde iletilmesi ve paylaşılması IoT tabanlı tedarik zincirlerini geleneksel anlamdan ayıran en önemli özelliktir. Bu sayede artık tüm süreç bir bütün haline gelmektedir (Oh ve Jeong, 2019).

Tedarik zinciri, tedarik zinciri yönetimi ve dijital tedarik zinciri yönetimi kavramları bu kısma kadar açıklanmıştır. IoT tabanlı tedarik zincirleri içerisinde ki en önemli unsurlardan birisi büyük veridir. Bu nedenle bir sonraki kısımda büyük veri kavramı açıklanacaktır.

1.2. BÜYÜK VERİ VE BÜYÜK VERİ ANALİĞİ

Dijital çağın yaşandığı günümüzde, endüstriye dayalı bir ekonomiden bilgiye dayalı bir ekonomiye geçiş yaşanmaktadır. Yaşanan geçişe bağlı olarak, elimizde bulunan büyük veri miktarı da her geçen gün artarak birikmektedir. Yapılan çalışmalarda

2025 yılına kadar her gün, 463 exabyte veri üretileceği tahmin edilmektedir. Bu söz konusu devasa veri, insanoğluna bir takım avantajların yanında birçok zorlukta beraberinde getirmektedir. Çeşitli yollarla elde edilen verilerin uygunsuz şekilde işlenmesi; gizlilik ihlallerine, dolandırıcılıkta artışa, veri kaybına ve çok daha fazlasına yol açabilmektedir. Buna rağmen söz konusu veriler doğru bir şekilde işlenirse, teknolojiye muazzam bir büyüme ve gelişme elde edileceği bir gerçektir. Verileri geleneksel veritabanlarında depolamak gibi geleneksel işleme ve analiz etme yöntemleri, büyük verileri işlemede veri miktarının çok büyük boyutlarda olmasından dolayı zayıf kalmaktadır (Chaudhary ve Alam, 2022).

Büyük veri ve analizi, modern bilim ve ticaretin merkezinde yer almaktadır. Bu veriler çevrimiçi işlemlerden, e-postalardan, videolardan, seslerden, resimlerden, tıklama akışlarından, günlüklerden, gönderilerden, arama sorgularından, sağlık kayıtlarından, sosyal ağ etkileşimlerinden, bilim verilerinden, sensörlerden, cep telefonlarından ve bunların uygulamalarından üretilmektedir (Eaton vd., 2012; Schneider vd., 2012). Üretilen bu veriler, veritabanlarında depolanmakta ve tipik veritabanı yazılım araçları aracılığıyla yakalanmaları, biçimlendirilmeleri, saklanmaları, yönetilmeleri, paylaşılmaları, analiz edilmeleri ve görselleştirilmeleri zorlaşmaktadır (Sağiroğlu ve Sinanc, 2013).

Son yıllarda, bilim dünyası büyük veri, iş analitiği, akıllı yaşam ve çalışma ortamlarına artan bir vurgu yapmaktadır. Bu görüşler ağırlıklı olarak uygulama odaklı olsa da kuruluşlar, bireyler, işletmeler, topluluklar ve hükümetler için değer yaratmak ve elde etmek için büyük hacimli verilerin nasıl yararlı bir şekilde dağıtılabileceğini araştırılan konuların başında gelmektedir (McKinsey Global Institute, 2011). Günümüzde büyük veri, verileri yalnızca belirli kurallara göre analiz etmekle kalmayıp aynı zamanda bir olayın tahmini olasılığını da sağlayabilen bir araç haline gelmiştir. Söz gelimi; bireylerin kişisel işlemlerini, tüketici seçimini, arama davranışını, trafik modellerini veya hastalık salgınlarını tahmin etmek için makine öğrenimi ve web analitiği olsun birçok yöntem ile büyük veriler analiz edilmektedir (George vd., 2014).

Büyük veri çağı, eşi benzeri görülmemiş bir ölçekte dijital veri üretme, toplama ve depolama yeteneğimizin ve aynı zamanda bu verileri analiz etme ve bu verilerden

değer çıkarma arzumuzun kaçınılmaz sonucu olarak ortaya çıkmıştır. Ortaya çıkan bu veriler günümüzde çok çeşitli alanlarda toplanmaktadır (Dong ve Srivastava, 2013).

Teknolojinin hızla gelişmesi ile beraber üretim süreçlerinin değişmesi, müşteri istek ve beklentilerinin farklılaşması, her pazarın farklı özelliklerinin ortaya çıkması ve dünyanın her yerinden alışveriş yapabilme olanağının gelmesi gibi faktörlerden dolayı işletmeler büyük verileri etkin ve verimli bir şekilde analiz etmek zorunda kalmıştır. İşletmeler açısından bakıldığında şeffaflık ve hesap verilebilirlik gibi ilkelerden dolayı dışa açık bir yapı ortaya çıkmış, bu yapı ise dış dünya ile veri akışını sürekli hale getirmiştir. Bu durum karşısında işletmeler sadece kendi bünyesinde sahip olduğu verileri değil aynı zamanda sektörel verileri de analiz ederek değer yaratma ve dolayısıyla rekabet etmek zorunda kalmıştır.

Üretim süreçlerindeki her bir makine ve aşamada sensörlerin olması üretim alanları içerisinde veri paylaşımını ve bu veri paylaşımına göre faaliyet göstermeyi zorunlu hale getirmiştir. Artık üretim süreçlerindeki bir istasyonda meydana gelen arıza önceki ve sonraki iş istasyonları ile paylaşılmakta ve üretim bu şekilde sağlanmaktadır. Diğer taraftan bir istasyonda yaşanan problemden dolayı o istasyonda üretimin durması karşısında önceki istasyonlar sensörler aracılığı ile bilgilendirilerek üretim durmaktadır. Bu ve bunun gibi durumlarda karşısında da artık büyük veriler üretilmekte, hangi durumlarda istasyonlar ve makinelerde sorunlar olduğu bilinmekte, gecikmelerin nedenleri doğrudan sensörlerden elde edilen verilerden tespit edilebilmektedir. Aynı zamanda stoklar sensörler aracılığı ile takip edilmekte, tedarik zincirleri ilk halkadan son halkaya kadar bilgi akışı içerisinde bir yapıya bürünmektedir. İşletmeler, süreç ve makinelere entegre edilmiş büyük sensörler ve geliştirilmiş olan iletişim ağı ile büyük verileri toplamakta ve analiz etmektedir (Ebner vd., 2014). Analiz ederken gizli kalmış bilgilere de erişmektedirler. Bu durum eldeki veri miktarını ve çeşidini arttırdığı gibi analizlerinde daha doğru olmasını olanaklı kılmaktadır. Bu veri türleri içerisinde doğru ve güvenilir veriler ile yapılan analizler sonucunda işletmelerin üst yönetimleri stratejik kararlar almaktadır. Çok boyutlu bir değerlendirme olduğu için alınacak kararların da başarısı aynı oranda artmaktadır (Dreischmeier vd., 2015). Geliştirilen dinamik veri elde etme ve işleme süreci işletmelerin gelişmiş analitik becerilere sahip olmasını gerektirir. Çünkü anlık veriler,

olağan akışın dışında anlık ortaya çıkan durumları da içermekte ve yapılacak analizlerde bu doğrultuda anlık olarak yapılmalıdır (Kitchens vd., 2018). Bu nedenle büyük veri süreçlerinin dinamik bir yapıda olması gerekmektedir. Etkin ve verimli işleyen büyük veri analiz etme süreci işletmeler için önemli bir rekabet gücü sağlamaktadır (Karaboğa ve Zehir, 2020). Anlık yapılan analizler sonucunda, işletmeler pazarlara yeni ürünler üreterek avantaj sağlayabilmekte ve büyük veriler aracılığı ile inovasyon faaliyetlerine yön verebilmektedir (Morabito, 2015).

1.2.1. Büyük Veri Kavramı

Son sanayi devrimi ile birlikte yaşanan son on yıllık gelişmeler dijital araçları farklı bir boyuta getirmiştir. Artık karar verme süreçleri değişmiş, üretimde teknoloji yaygın olarak kullanılmaya başlanmıştır. Endüstri 4.0 olarak adlandırılan yeni sanayi devrimi ile beraber dijital çağ başlamıştır. Yaşanan bu gelişmelere bağlı olarak dijital araçlar ve teknoloji hayatımızın her alanına girmiştir. Örneğin üretim alanlarında robotlar kullanılmaya başlanmış, sensörler aracılığıyla makinelerin birbirleri ile etkileşimi sağlanmış bu durumda hataları minimize etmenin yanında maliyet avantajı getirmiştir. Bir diğer yandan tedarik zinciri alanında dijital uygulamalar farklı bir boyuta dönüşmüştür. Söz gelimi artık bir mağazadan alışveriş yaptığımızda o ürünün stoklardan çıktığı tedarikçilere kadar uzanan bir ağda paylaşılmaktadır. Bu durum sipariş geldiğinde de benzer durumdadır. Buna ek olarak tedarikçiden işletmelerin sipariş ettiği hammadde ya da ara mamul yola çıktığı andan itibaren izlenebilir bir hale gelmiştir. Diğer taraftan sensörlerin bu derece etkin kullanımı ve tedarik zincirlerinin gelişimi büyük miktarlarda verilerin ortaya çıkmasını ve bunların işlenerek faydalı bilgiler çıkarmayı zorunlu hale gelmiştir. Bir diğer taraftan insanlar, gözlerini açtığı andan itibaren her an bir veri üreten varlıklara dönüşmüştür. Artık firmalar cep telefonlarımızda yaptığımız işlemlere, gezindiğimiz internet sayfalarındaki davranışlarımıza göre tasarımlar yapmakta ve örnekler sunmaktadır. Buna benzer her alanda ortaya çıkan büyük miktardaki verilerin kullanılması çağımızda ayrı bir meslek olarak ortaya çıkmıştır. Bu yeni trende yani büyük veri olarak adlandırılan bu yeni kavrama yön verebilmek için detaylarının bilinmesi ve nasıl kullanılacağına anlaşılması önem arz etmektedir.

Büyük verinin bir terim olarak olmasa da kavram olarak doğuşu, genellikle Doug Laney tarafından 2001 yılında yayınlanan “*3-D Data Management: Controlling Data Volume, Velocity, and Variety*” başlıklı bir META Group raporuyla ilişkilendirilmektedir (Laney, 2001). Büyük veri genellikle yüksek hacimli, yüksek çeşitlilikte ve yüksek hızda veri olarak adlandırılmaktadır (McAfee ve Brynjolfsson 2012). Büyük veri, kuruluşlar tarafından akıllı telefonlar ve diğer multimedya cihazları, mobil uygulamalar, jeolojik konum izleme cihazları, uzaktan algılama ve radyo dalgası okuma cihazları, kablosuz algılama cihazları ve diğer benzer kaynaklar gibi çeşitli kaynaklardan toplanan muazzam veri deposu olarak bilinmektedir (Yin ve Kaynak 2015).

Büyük veri kavramı, yöneticilere karar verme sürecinde destek sağlayan, süreç otomasyonu ile birlikte düşük maliyetli faaliyet göstermeyi olanaklı hale getiren, sürecin her aşamasından hızlı bir biçimde elde edilen oldukça yüksek miktardaki bilgilerdir. Büyük veri, geleneksel veri işleme araçlarına uygun olmayan, ancak ondan elde edilen önemli içgörülerden, işletmeleri stratejik karar almaya yönlendirme potansiyeline sahip önemli ve devasa miktarda veriyi temsil etmektedir (Khan vd. 2017).

Büyük veri, sürekli miktar olarak artmaya devam eden, veri tabanlarında saklanan ve kolaylıkla işlenemeyecek olan çok sayıda veriyi ifade etmektedir. İlk bakışta birbiriyle alakasız olarak görünen ama bir sürecin tüm aşamalarından elde edilen devasa boyutta ki bu verileri, uygun kümelerle ayırmak ve aralarındaki ilişkiyi kurarak analizler yapmak hayati öneme sahiptir. Büyük verileri kullanılırken, devasa veri kitlelerinden küçük miktardaki örnekler alarak analizler yapmak hataya sürüklemektedir. Bu nedenle büyük verilerin tamamının ele alınması, kümelerle ayrılması ve dönüştürme işlemlerinin yapılarak analizler yapılması başarıya götürmektedir. Günümüzde sadece bir internet sitesine giriş yapan ve işlem yapan her bir bireyin her bir hareketi ayrı bir veri oluşturduğundan dolayı elde edilen bir günlük verilerin bile ne derece devasa boyutlarda olduğu anlaşılmaktadır. Son sanayi devriminin en önemli bileşenlerinden birisi olan nesnelerin interneti (IoT) aracılığıyla elde edilen veriler her bir veri üretici tarafından ortaya çıkarıldığı için oldukça çeşitli ve çok miktardadır. Büyük veri genel bir ifade ile elde edilen devasa verilerin analiz edilerek elde edilen sonuçlar katma

değeri olacak şekilde sunulması şeklinde tanımlanmaktadır. Bir başka ifade ile büyük veri, geliştirilen yeni teknolojik araçlar ile çok sayıda verinin elde edilmesi, depolanması, işlenmesi ve analiz edilerek değerli sonuçlar elde edilmesidir (Shehab vd., 2011).

Büyük veriler, yapılandırılmış, yapılandırılmamış veya yarı yapılandırılmış veri kümeleri türleri olarak sınıflandırılmaktadır (McAfee ve Brynjolfsson 2012). Yapılandırılmış veriler, iyi organize edilmiş ve sistematik verileri ifade etmektedir. Herhangi bir sistematik düzen veya yapı olmaksızın ham sürümde basitçe depolanan veriler, yapılandırılmamış veriler olarak bilinmektedir (Alam 2012). Bu ikisinin arasında, verilerin bir kısmının yapılandırılmamış ve bir kısmının yapılandırılmış olduğu yarı yapılandırılmış veriler bulunmaktadır.

Büyük veri, son sanayi devriminin hayatımıza kattığı sensörler, internet davranışları, dijital görüntüler, kayıtlar ve cep telefonları gibi kaynaklardan elde edilen verilerdir. Başka bir ifade ile ise, sensörlerden elde edilen çıktılar, müşteri davranışlarının kaydedilerek sayısallaştırılması, GPS sinyalleri gibi kaynaklardan elde edilen devasa veri setleridir (Manovich, 2011). Büyük verilerin elde edilmesi, saklanması, analiz edilmesi gibi her aşamada gelişmiş algoritmalar ve bilgisayarlar kullanılmaktadır (Davenport vd., 2012). Çünkü büyük veriler basit istatistik yöntemlerle analiz edilemeyen sürekli olarak gelişen dinamik yapıdaki veri setleridir. Büyük veri analizi ile gerçekleştirilen dinamik deneyler, belirli koşulların etkili olma olasılığını tahmin ederek, rastgeleliği dinamik olarak yeniden ağırlıklandırmakta ve bu yolla geleceğe dair daha etkili koşullar sunan daha iyi bir öğretim politikasına olanaklı kılmaktadır (Fischer vd., 2020).

1.2.2. Büyük Verinin Tarihçesi

Büyük veri ilk kez yirminci yüzyılın son döneminde Francis Diebold tarafından sayısal analiz yapılan alanlarda analiz edilecek verilerin oldukça fazla miktarda olduğu şeklinde ifade edilmiş; resmi olarak ise 1997 senesinde Cox ve Ellsworth tarafından kullanılarak hayatımıza girmiştir. Cox ve Ellsworth (1997) yaptığı çalışmada, elde edilen verilerin devasa boyutlarda olduğunu ve depolanmasında kaynakların yetmediğinden bahsederek büyük veri sorunundan bahsetmiştir.

Sociomantic tarafından hazırlanan “The Big Data Bang” adlı infografik veriler ışığında büyük verinin gelişimine etki eden olaylar ya da çalışmalar şu şekilde sıralanmaktadır (Burns, 2015):

- 1969 senesinde ilk bilgisayar ağının ABD’de kurulması.
- 1991 yılında world wide web (www)’in tasarlanarak tüm dünyada kullanılmaya başlanması.
- 1994 yılında ilk banner reklamının yayımlanması.
- 1996’da ilk akıllı telefonun icat edilmesi
- 1997 yılında ilk mobil reklamın yapılması.
- 2000’de cep telefonlarında internet kullanımının başlaması.
- 2005 yılında dünya genelinde internet kullanan kişi sayısının bir milyar rakamını geçmesi.
- 2007 yılında facebook’un kişiye özel reklamlar sunmaya başlaması.
- 2008’de youtube’ın videolarda reklam göstermeye başlaması.
- 2009’da kişiselleştirilmiş reklamların doğru zamanda gösterilmeye başlanması.
- 2010’da twitter’da reklamların yapılmaya başlanması.
- 2011’de Endüstri 4.0’ın ilan edilmesi.
- 2011’de internet sayfalarının sayısının bir trilyonu geçmesi.
- 2012’de facebook Exchange’in uygulanmaya başlanması.
- 2012’de internet üzerinden verilen reklamlar ile televizyon reklamlarından daha fazla gelir elde edilmesi.
- 2014’te pinterest’in reklam pinlerini kullanmaya başlaması.

1.2.3. Büyük Verinin Bileşenleri

Hayatımıza inanılmaz bir hız ile yön veren etkenlerden birisi olan büyük veri kavramı kendisini oluşturan bir takım alt bileşenlerden meydana gelmektedir. Büyük veri kavramı ile ilgili çalışmalarda büyük verinin bileşenleri ilk olarak:

- Hacim (volume),
- Çeşitlilik (variety),

- Hız (velocity), olarak belirtilmiş ve bu bileşenlerin ilk harflerinin bir araya getirilmesiyle 3V (Laney, 2001) şeklinde ifade edilmiştir.

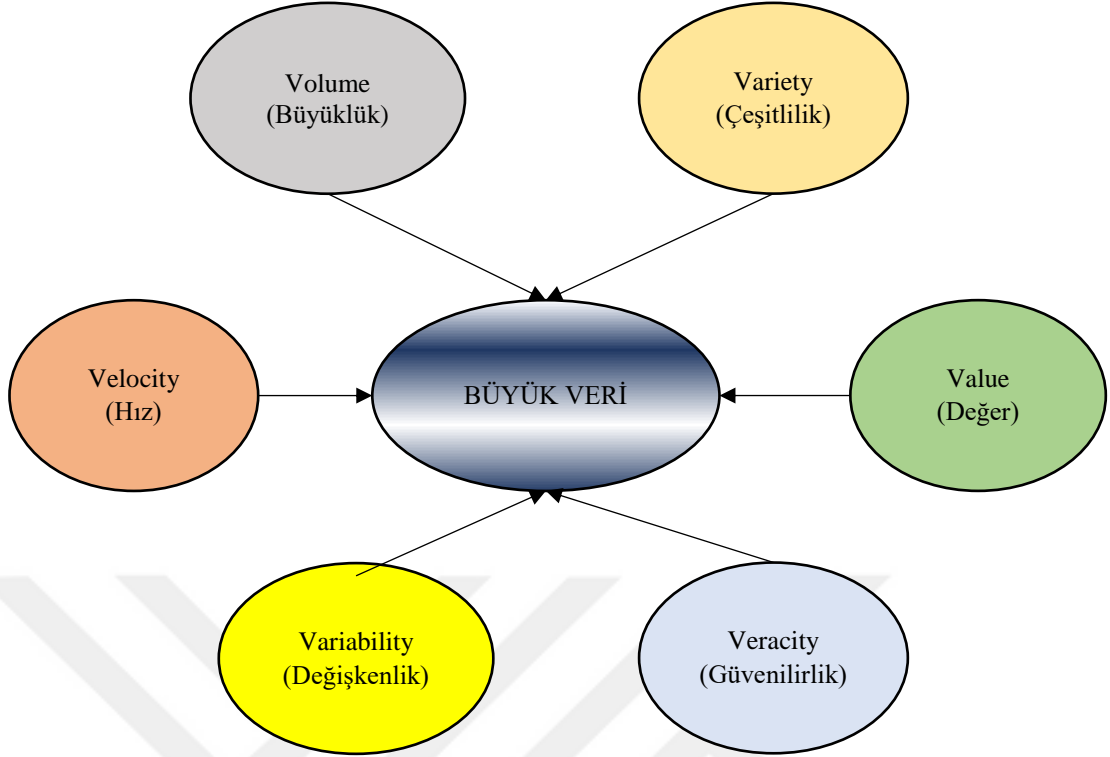
Büyük veri kavramının yeni olması ve çalışmaların kısıtlı olmasından dolayı başlangıçta 3V olarak ifade edilen bu bileşenler sonraki dönemlerde çeşitlenerek 6V haline gelmiştir. Bu doğrultuda belirtilen üç bileşene ek olarak:

- **4V:** Değişkenlik (variability) (Amanullah vd., 2020),
- **5V:** Doğruluk (veracity) (Shu, 2016)
- **6V:** Değer (value) (Gupta ve Gupta, 2016) bileşenleri de eklenmiştir.

Büyük veri kavramı sahip olduğu bu altı bileşen ile birlikte ele alındığında birçok zorluğu içeren karmaşık bir yapıya sahip olduğu görülmektedir (Katal vd., 2013). Büyük veri kavramını daha iyi anlamak için bileşenlerinin bilinmesi ve söz konusu bileşenlerinde hangi anlamda kullanıldığının anlaşılması gerekmektedir. Farklı görüşlere göre büyük veri bileşenleri 3V, 4V, 5V ve 6V olarak adlandırılrsa da anlamlarında farklılıklar bulunmamaktadır. Şekil 1.8’de gösterilen büyük verinin bileşenleri olarak ifade edilen söz konusu altı değişken sırasıyla açıklandığında konu daha iyi anlaşılacaktır:

- **Volume (Veri Büyüklüğü):** Volume ya da hacim bileşeni, mobil dijital veri oluşturma cihazları ve dijital cihazlar dâhil olmak üzere herhangi bir farklı kaynaktan gelen büyük miktarda her türlü veriyi ifade etmektedir. Bu büyük miktarda veriyi toplamamanın, işlemenin ve analiz etmenin sağladığı fayda, insanlar ve şirketler için değerli bilgiler elde etmede bir takım kolaylıklar ve zorluklar doğurmaktadır (Koseleva ve Ropaite, 2017).
- **Velocity (Hız):** Hız bileşeni, veri transferlerinin hızını ifade eden büyük veri bileşenidir. Verilerin içeriği, tamamlayıcı veri koleksiyonlarının özümsemesi, önceki verilerin veya eski koleksiyonların tanıtılması ve birden çok kaynaktan gelen farklı akışlı veri biçimleri aracılığıyla sürekli olarak değişmektedir. Bu açıdan bakıldığında, çevrimiçi ve akış verilerini yeterince işlemek ve analiz etmek için yeni algoritmalara ve yöntemlere ihtiyaç duyulmaktadır. Bu bakımdan büyük veri analizini geleneksel istatistik analiz yöntemlerinden ayıran temel faktörlerden birisi hızdır (Bello-Orgaz ve Camacho, 2016).

- **Variety (Çeşitlilik):** Çeşitlilik bileşeni; büyük verinin içerisinde gerek yapılandırılmış gerekse de yapılandırılmamış formatta olan çok farklı türde nicel ve nitel değişkenleri barındırdığını ifade etmektedir (Kaur vd., 2018). İşletmelerde iş süreçlerine dair çeşitlilik çok fazladır. Örnekte klinik veriler, tıbbi görüntüleme verileri, giyilebilir sensörler, laboratuvar incelemeleri ve simülasyon sonuçları gibi bir olayda bile oldukça fazla çeşitte veri bulunmaktadır (Viceconti vd., 2015).
- **Value (Değer):** Elde edilen büyük verilerin faydalı katma değer sağlayan verilere dönüştürülmesi gerektiğini ifade eden büyük veri bileşenidir. Büyük verinin değeri ilk olarak Gantz ve Reinsel (2012) tarafından tartışılmış ve büyük veri teknolojilerinin, veri analizi ve bilgi yeteneği ile büyük hacim, yüksek hız ve çok çeşitli verilerden ekonomik değer çıkarımına dayandığını ana hatlarıyla belirtmişlerdir (Cheng vd., 2017).
- **Veracity (Güvenilirlik):** Bu bileşen büyük veri kaynaklarından elde edilen verilerin ve analizinden elde edilen sonuçların güvenilir yani doğru olmasını ifade eder. Bu bileşen çerçevesinde elde edilen ham verilerin doğru olması, temizlenme ve yapılandırma işlemlerinin doğru yapılması gerekmektedir. Bu bileşene uygun olarak elde edilmiş olan verilerin kullanıldığı analizler daha doğru kararlar almayı sağlamaktadır. Büyük veri analizlerinde elde edilen her verinin doğruluğu ve güvenilirliği garanti altında olmadığı için kullanılacak verilerin bu açıdan incelenerek değerlendirilmesi gerekmektedir (Lazer vd., 2014).
- **Variability (Değişkenlik):** Değişkenlik, verilerin işleme periyodu sırasında veya yaşam döngüsünün herhangi bir aşamasında değişebileceği anlamına gelir (Charles ve Gherman, 2013). Çeşitlilik ve değişkenlik artarsa, büyük veriden beklenmeyen, gizli ve değerli bilgilerin keşfedilme olasılığı vardır (Gao vd., 2020).



Şekil 1. 7. Büyük Verinin Bileşenleri (6V)

Kaynak: Bora, 2019

Büyük veriye ait yapılan tanımlar ve bileşenleri incelendiğinde büyük verinin sadece çok sayıda veri olmadığı aynı zamanda tüm bileşenlerini kapsayan büyük bir veri kümesi olduğu anlaşılmaktadır. Yani büyük veri sadece çok miktarda devasa veriler değildir. Aynı zamanda oldukça çeşitli sayıda değişkene ait olan, hızla üretilen güvenilir kaynaklardan gelen, hacimsel olarak oldukça büyük miktarda olan ve değerlendirilmesi ile faydalı sonuçlar elde edilebilen veri kümeleri büyük veri anlamında gelmektedir.

1.2.4. Büyük Veri Kaynakları

Son sanayi devrimi ile beraber teknolojinin her alanda hayatımıza girmesi sonrasında akıllı cihazlar, sensörler ve nesnelerin interneti gibi Endüstri 4.0 bileşenlerinin her anımızda karşımıza çıkması büyük veri kavramının sıklıkla telaffuz edilmesine neden olmuştur. Büyük veri her alanda telaffuz edilirken üç önemli soru ortaya çıkmıştır. Bu sorular büyük verilerin nasıl elde edileceği, nerede saklanacağı yani büyük veri tabanları ve büyük verilerin nasıl analiz edileceğidir. Tanımlardan ve bahsedilen özelliklerden yola çıkarak özetle büyük verinin yapay zekâlar yardımıyla elde edildiği

ve saklandığı söylenebilir. Sözelimi cep telefonlarımızda yaptığımız her türlü işlem ve dokunuş, internet sayfalarındaki her bir tıklama, güvenlik kameralarındaki her bir piksel, her bir resim, makinelerin sensörlerinin elde ettiği her veri bir büyük veri kaynağını oluşturmaktadır. Yapay zekâ yardımı ile üretilen ve oldukça karmaşık yapıdaki çok sayıdaki verilerin analizi de ancak yapay zekâ algoritmaları ve yazılımlar ile yapılabilmektedir.

Günümüzde işletmelerin karar mekanizmasında önemli bir rol oynayan büyük veriler, birçok kaynaktan üretilmektedir. Günlük hayatımızda kullandığımız cep telefonlarından yaptığımız işlemler, bilgisayarlarımız aracılığıyla internet gezinmelerimiz, tıklamalarımız ve sosyal medya platformları başlı başına birer büyük veri kaynağıdır. Bunlara ek olarak üretim ortamlarında kullanılan sensörler ve nesnelerin interneti aracılığıyla makinelerin ürettikleri verilerde önemli birer büyük veri kaynağıdır. Ayrıca sağlık hizmetlerinin sunumu, operasyon yönetimi, tedarik zinciri süreçleri, bankacılık işlemleri ve borsalarda önemli büyük veri kaynaklarından (George vd. 2014).

Büyük veriler sosyal medya, kullanıcıların oluşturduğu internet verileri, bireylerin kişisel blogları, sensörler, cep telefonu sinyalleri ve kayıtlar, fotoğraflar ve videolar gibi çok çeşitli kaynaklardan elde edilmektedir (Demirtaş ve Argan, 2015). Tablo 3'te gösterilen büyük veri kaynakları, işletmelerde performansın artırılması amacıyla büyük verilerin kullanılması sürecinde bilgi teknolojisinin bir bütün halinde kullanılmasıyla verilerin elde edildiği ortamlardır (Kung vd., 2015).

Farklı kaynaklar aracılığıyla elde edilebilen büyük veriler, sosyo-ekonomik politikalar geliştirmek ve çalışma ortamlarının dijital dönüşümünde kullanılmaktadır (Einav and Levin, 2014). Elde edilen büyük veriler kullanılarak işletme yöneticilerinin karar verme mekanizması da geliştirdikleri stratejiler daha etkin olmakta ve bu yolla işletme performansına etki etmektedir (Varian, 2014).

İşletmeler büyük verileri bir değere dönüştürmek için faaliyet gösterdikleri alanda hangi veri kaynaklarının mevcut olduğunu, ne tür veriler sağladıklarını ve bu verilerin nasıl ele alınacağını belirleyerek karar verme sürecine etki etmektedir. İşletmelerin

kendilerine has ve amacına uygun olarak geliştirdikleri büyük veri mimarisi, işletmelere stratejik katkı sağlamaktadır. Geliştirdikleri bu veri mimarisi, verilerin elde edilmesi, analizi ve depolanması da dâhil olmak üzere tüm yaşam döngüsüne entegre edilmelidir (Blazquez ve Domenech, 2018).

Tablo 1. 2. Büyük Veri Kaynakları

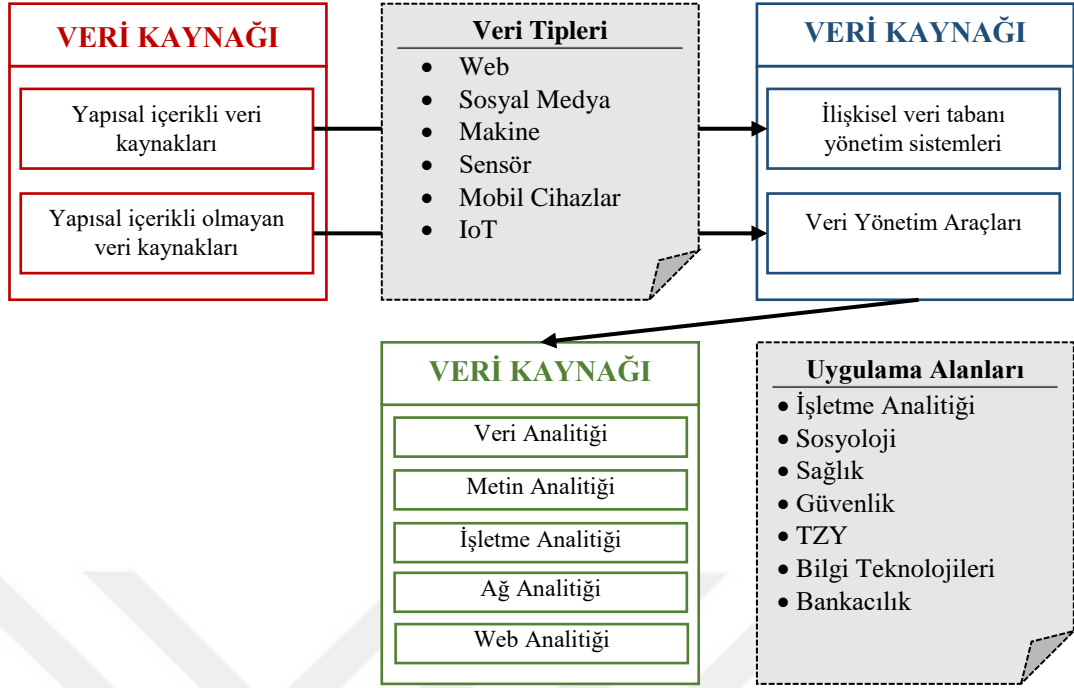
<ul style="list-style-type: none">• İç Kontrol• İç Sistemler• Müşteri İşlemleri• Sektöre Özgü Trendler• Robotlar	<ul style="list-style-type: none">• Sosyal Medya• Mobil Cihazlar• E-Mail / Mesajlar• Dijital Ayak İzi
<ul style="list-style-type: none">• İnternet• Bağlantılı Cihazlar• Radyo Frekansı ile Tanımlama Cihazları• İnternet Aramaları	<ul style="list-style-type: none">• Sensörler• Dronlar• Güvenlik Kameraları• Pazar Araştırmaları• Tedarikçiler

Kaynak: Onay, 2020

İşletmelerde büyük veri mimarisinin tasarımı, ölçeklenebilirlik, veri kullanılabilirliği, veri bütünlüğü, veri dönüşümü, veri kalitesi, veri kaynağı, büyük hacimli bilgilerin yönetimi, veri heterojenliği, farklı kaynaklardan gelen verilerin entegrasyonu, veri eşleştirme, yanlılık, bu tür verileri uygun şekilde analiz etmek için araçların mevcudiyeti, işleme karmaşıklığı, mahremiyet ve yasal sorunlar ve veri yönetişimi gibi içerdiği birçok zorluğu dikkate alacak şekilde yapılmalıdır (Fan vd., 2014; Jagadish vd., 2014; Hashem vd., 2015).

Büyük veri mimarisi yararlanıcılarına araştırma yöntemlerini değiştirme, disiplinler arası araştırma yapma, mevcut durum analizi yaparak geleceğe yönelik tahminler geliştirme, sürekli iyileştirme gibi birçok avantaj sağlamaktadır (Jin vd., 2015).

Büyük veri mimarisi Karaöz (2018) tarafından şu şekilde görselleştirilmiştir:



Şekil 1. 8. Büyük Veri Mimarisi

İşletmelerin günümüzde karşı karşıya olduğu değişken sosyo-ekonomik faktörler, insan davranışlarının ve algılarının çeşitliliği gibi nedenlerden dolayı büyük veri mimarilerini oluşturmakta problemler yaşamaktadır. Ancak etkin bir şekilde süreçlere dair verilerin elde edilerek işlenmesi rakiplerine karşı önemli bir üstünlük sağlamaktadır. Yöneticiler büyük veri analizi neticesinde elde ettikleri sonuçları kullanarak, pazarlarda oluşan fırsatları rakiplerinden önce tahmin ederek stratejiler geliştirme avantajına sahiptir. Bu yolla işletmeler daha hızlı karar alma mekanizmasına sahip esnek ve çevik bir yapıya kavuşmaktadır (Vicente vd., 2015).

Bireylerin internet tabanlı sanal ortamlardaki davranışları, sosyal ve ekonomik analizler için mevcut veri kaynaklarının katlanarak artmasına neden olmuştur ve bu durum, anketler ve resmi kayıtlar gibi geleneksel veri kaynaklarının ötesinde sosyo-ekonomik araştırmalar yürütme olanaklarını genişletmiştir. Bu yeni verilerin üretilmesinin birçok nedeni olmasına rağmen, bunların oluşturulma biçimlerinin önemli etik ve yasal sonuçları vardır. Örneğin, bir satın alma siparişindeki kişisel veriler, Twitter'daki herkese açık bir profildeki verilerle aynı amaçlar için kullanılamaz. Bir dereceye kadar, verilerin kullanımı nasıl üretildikleri ile sınırlıdır. Bu durum yeni doğan geleneksel olmayan sosyal ve ekonomik veri kaynaklarını,

verileri üreten kullanıcının amacına göre gözden geçirmeye ve sınıflandırmaya mecbur kılmaktadır (Blazquez ve Domenech, 2018).

1.2.5. Büyük Veri Kullanımını Teşvik Eden Nedenler

Bilgi işlem teknolojileri ile elde edilen büyük verilerin hızla artması, analiz edilecek veri çeşidi ve miktarını da oldukça hızlı bir biçimde arttırarak, karar verme süreçlerini, oldukça karmaşık hale getirmektedir. İşletmelerin kendi içerisinde topladığı verilerin yanı sıra faaliyet gösterdiği endüstri içerisinde de veriler elde etmektedir. İşletmelerin elde ettiği bu verileri doğru bir biçimde işlemesi ve analiz etmesi hayatta kalabilmesi için bir zorunluluktur. İşletmeler elde ettikleri büyük verileri kullanarak, gelişmiş teknolojileri takip etmekte, daha ucuz girdiler bulmakta, maliyetleri düşürmekte, hataları minimize etmekte ve stratejik kararlarını doğru ve zamanında almaktadır. Ortaya çıkan bu durum temel olarak işletmelerin büyük veriyi kullanmasını zorunlu kılmıştır. Geleneksel yönetim anlayışı içerisinde ayrılarak yeni dijital bir çağa dönüştüğümüz günümüzde işletmelerin başarısının da bu dijital süreç ve verilerine bağlı olduğu söylenebilir. Elde edilen büyük verilerin etkin bir şekilde işleterek bir değere dönüştürülmesi gerekliliği doğrudan ortaya çıkan bir durum olmaktadır.

Büyük veriye olan mevcut ilgiye birkaç faktör katkıda bulunmuştur (Eaton vd., 2012; Pence, 2014):

- Bilgisayar belleği çok daha ucuz hale geldi ve aranması daha kolay hale geldi. Bir USB flash sürücünün sağladığı gigabayt veri depolama başına maliyet, yaklaşık 10 yıl önce ilk kez piyasaya sürüldüklerinde 8.000 dolardan fazlayken bugün 94 sente düşmüştür.
- Sosyal ağlar, resmi olarak kısa süreli konuşmaları toplar. Twitter günde 7 Terabayttan (TB) fazlasını üretir; Facebook 10 TB'tan fazla ve bazı işletmeler zaten petabayt aralığında veri depolamaktadır.
- İşletmeler daha küreselleştikçe, birden çok yerde olup bitenleri koordine etmek daha karmaşık ama aynı zamanda daha önemli hale gelmiştir.

İşletmelerde büyük veri kullanımını teşvik eden faktörler bir arada verilecek olursa;

- Verilerin düşük maliyetli depolanması,

- Teknolojide yaşanan gelişmeler,
- Anlık analizler ile aksaklıkların minimize edilmesi,
- Dijital ikizler oluşturarak sanal ortamda faaliyetleri planlayabilme,
- Bulut bilişimin hızla hayatımıza girmesi,
- Gelişmiş yapay zekâ analiz teknikleri,
- Büyük veri analizinin ayrı bir meslek olarak ortaya çıkması.

1.2.6. Büyük Verinin Kullanım Alanları

Günümüzde teknolojinin yaygın olarak internet tabanlı ortamlar ile birlikte kullanılmaya başlanması birçok farklı kaynaktan büyük veri elde edilmesini olanaklı hale getirmiştir. Bütün sektörlerde birçok farklı amaçla kullanılan büyük verilerin analizleri karar alma mekanizmaları için önem arz etmektedir. Artık toplanan verilerin analiz edilmesiyle birlikte (Toptaş, 2021);

- Genetik olarak hangi genin hangi hastalığı doğuracağı,
- Hava durumunu doğru tahmin edilmesi,
- Bireylerin kredi geri ödeme kapasitesi,
- Sinemalarda gişe hasılatı tahmini,
- Ürün sepeti tahminleri,
- Satın alma tercihleri,
- Tatil yeri seçiminin tahmin edilmesi.

Buradaki en büyük sorun elde edilen, toplanan ve depolanan verilerde nereye bakılacağına bilinmemesidir. Anlamsız veriler anlamlandırılarak ortaya çıkan sonuçlar bize gelecekteki davranışlar hakkında tahminler vermektedir. Bu sayede büyük veri ile kurumlar önceden bilinmeyen bilgileri elde edilen verilerin analizi ile ortaya çıkararak şirkete artı değer katacak şekilde, karar verme süreçlerindeki süreyi minimize etmeyi hedeflemektedirler.

Büyük veri kullanabilecek sektörler bakılacak olursa: Danışmanlık, Finansal Hizmetler, Sigorta Aracılık Hizmetleri, Lojistik, Dış Ticaret, E-Ticaret, Bilişim, Telekom, Sağlık, Sosyal Hizmet, STK, Kamu, Sanat ve Kültür, Turizm ve eğlence, hizmet, perakende, medya ve reklam, iletişim, kimya, malzeme, çevre, kozmetik,

enerji ve maden, tarım, gıda, inşaat, gayrimenkul, emlak, üretim ve sanayi, otomotiv, tekstil, mobilya, beyaz eşya, hukuk ve finans olduğu görülmektedir. Büyük veri kullanabilecek sektörlerin yanı sıra bu sektörlerin departmanları: mali işler, insan kaynakları, pazarlama, müşteri hizmetleri, satış, Ar-Ge, satın alma ve lojistik şeklinde sıralanabilir (Toptaş, 2021).

1.2.7. Büyük Verinin Avantaj ve Dezavantajları

Büyük veri, yaşadığımız bu dönemin bir büyük veri dönemi olması dolayısıyla, geleneksel veri analiz platformlarında köklü değişiklikler yaratıyor. Bu tür büyük hacimli ve karmaşık veriler üzerinde herhangi bir analiz yapmak için, kullanıcıların gereksinimlerinin makul bir sürede karşılanması için doğru donanım ve yazılım platformlarının seçilmesi çok önemli bir karar haline gelmektedir. Araştırmacılar, daha önce hiç olmadığı kadar büyük veriler için yeni veri analizi teknikleri geliştirmek için çalışmaktadırlar ve bu da birçok farklı algoritma ve platformun sürekli geliştirilmesine yol açmaktadır (Singh ve Reddy, 2015).

Günümüzde sermaye ve emeğin yanında, veriler de tüm endüstrilerin vazgeçilmez bir parçası haline gelmiştir. ABD gibi gelişmiş ülkelerde 200 terabyte'ın altında verisi olan bir sektör kalmadığı düşünülmektedir. Bu anlamda veri bilimi yeni iş ve istihdam alanları arasında yer almaktadır. Büyük veri kullanımıyla beraber işletmeler; e- ticaret sitelerini ziyaret eden müşterilerin neler aldığı, nelere baktıklarını görmektedir. Böylece yöneticiler tüketici davranışlarını inceleyerek ona göre promosyonlar sunmakta ve potansiyel müşterilere ulaşabilmeyi başarmaktadır (Demirtaş ve Argan, 2015).

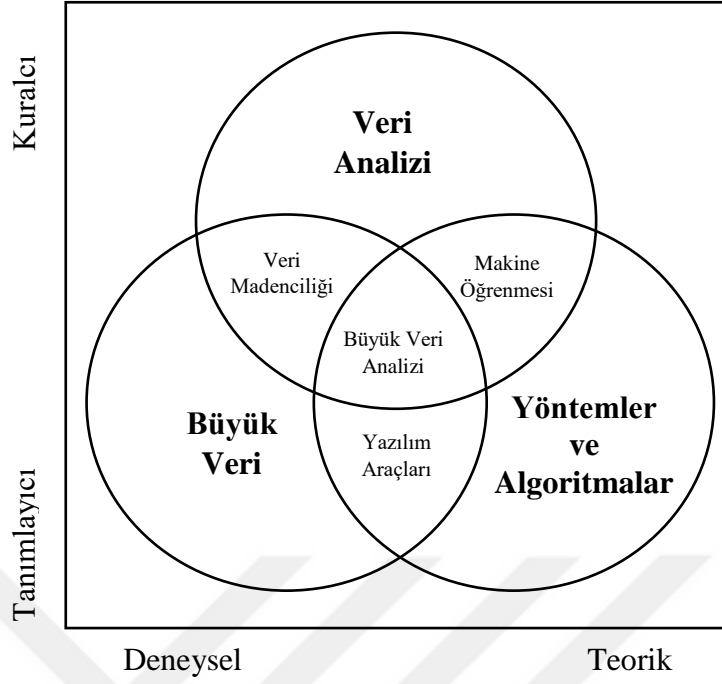
Büyük veri gelişimi ile beraber artık tüketiciler kendilerine özgü çok sayıda mal ve hizmete daha kolay ve daha hızlı ulaşabilme imkânına kavuşmuşlardır. Örneğin; herhangi bir mağazaya yakın mesafeden geçen tüketici, kendisine özgün bir üründe indirim kampanyası başladığına dair bir mesajı cep telefonundan alması gibi durumlar bu imkanlara örnek olarak sunulabilmektedir (Singh ve Reddy, 2015) Büyük veri ile, sosyal medyada bahsi geçen konuların analizleri yapılarak yeni trend ya da modaların neler olabileceğini tahmin etmek artık çok kolay olmuştur (İnukollu vd., 2014).

1.2.8. Büyük Veri Analitiği

Veri analizi, elde bulunan veri kümesinde yer alan değişkenler ve özellikler arasındaki birtakım ilişkileri tanımlamak için o veri seti üzerinde analizler yapmayı gerekli kılmaktadır. Yapılan bilimsel çalışmalar neticesinde geliştirilen hesaplamalı yaklaşımlar, veri analizine dayanan veri kümesinde yer alan gizli bağlantıları çıkarmaya yaramaktadır. Söz konusu iç görüleri ya da gizli bağlantıları tespit etmek amacıyla makine öğrenmesi ve veri madenciliği teknikleri kullanılmaktadır (Kaliraj ve Devi, 2022). İşletmeler artık bu yöntemleri iş süreçlerine dahil ederek karar verme süreçlerine entegre etmelidir (Chen vd., 2012). Bu yol ile alınacak kararların ve uygulanacak stratejilerin belirlenmesi işletmelerin performansının artırılması, kalitenin ve sürekli iyileştirmenin sürdürülebilirliği açısından oldukça önemlidir. Çünkü sürece ait, çok fazla değişken ve verinin teknoloji ile birlikte işlenmesiyle elde edilen sonuçlara dayanan kararların ve politikaların, geleneksel yöntemlere göre daha etkin sonuçlar vereceği açık bir gerçektir.

Büyük veri terimi, ilk olarak 1997 yılında, bir bilgisayarın ana belleğinde depolanamayacak kadar büyük veri kümelerini görüntülemenin zorluğunu açıklamaya çalışan NASA'da görev yapan bilim adamları tarafından ortaya atılmıştır (Cox ve Ellsworth, 1997). Büyük veri analitiği en temel ve kısa anlamıyla, sahip olunan verileri mevcut bilgi teknolojilerini ve yazılımları kullanarak ileri istatistiksel analiz yöntemleriyle işlemektir (Russom, 2011). Büyük veri analitiği, işletmelerin faaliyetlerine dair performansın artırılması için oldukça büyük miktardaki karmaşık yapıda ki verileri analiz ederek bazen tek bir veriye indirgenmesini sağlayan ve faydalı sonuçlar elde etmek için geliştirilen teknoloji ve yöntemlerdir (Kwon vd., 2014). Bir başka ifadeyle büyük veri analitiği ise, en temel olarak, yapılandırılmamış ya da ham olan büyük verilerde anlamlı çıkarımlar yapma sürecidir (Chaudhary ve Alam, 2022).

Büyük veri analizi, Şekil 1.9'da görüldüğü gibi veri bilimi içinde yer alan büyük veri, veri analizi ve geliştirilen yöntem ile algoritmaları içeren bir süreçtir.



Şekil 1. 9. Veri Bilimi Alanları

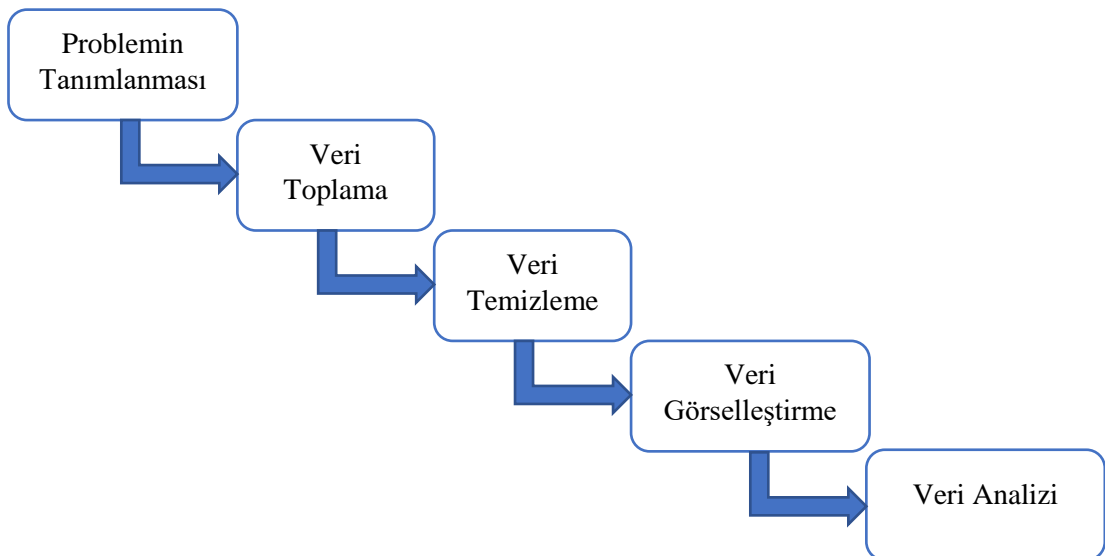
Kaynak: Kaliraj ve Devi (2022)

Büyük veri analizinin temel amacı, veri üretiminden sorumlu olan kaynağa ilişkin bir iç görü elde etmektir. Veri kaynağından elde edilen verilerin analiz edilmesiyle ulaşılan bilgi, işletmelerin müşterilerine ait davranışları anlamada ve pazar performansının ölçülmesinde önemli bir rol oynamaktadır. İşletmeler büyük veri analizi ile tüketici tercihlerini ölçmekte ve belirlediği saptamalara göre kampanyalar düzenlemektedir. Bu yol ile alakası olmayan ürün gruplarının birlikte alındığı tespit edilerek kampanyalar yapılmakta ve bu şekilde satışlar arttırılmaktadır. Geleneksel ürün ilişkilendirme teknikleri ile bu kampanyalar tarz kampanyalara dair çıkarımlar yapılamamaktaydı. Ancak büyük veriler sisteme entegre edilerek yapılacak analizler ile bahsedildiği gibi ürün ilişkilendirmeler yapılabilmektedir. Pazar sepeti analizleri büyük veriler kullanılarak yapıldığında kullanılan büyük veri analitiği teknikleri; ürün-ürün, müşteri-ürün ve müşteri-müşteri eşleştirmesini yapmayı olanaklı hale getirmektedir. Çünkü büyük veri analitiği kapsamında yapılan analizler satış öncesi tüketici verileri ile satın alım sonrasında oluşan verilerin ilişkilendirilmesini sağlamaktadır. Benzer bir biçimde müşteri temsilcileri ile görüşmeler, e-postalar ve iadeler gibi geri dönüşüm mekanizmaları kullanılarak elde edilen verilerin analiz

edilmesiyle de sürekli iyileştirme olanaklı ve etkin hale gelmektedir (Chaudhary ve Alam, 2022).

İşletmelerin çok çeşitli yollardan elde ettiği büyük veriler işlenmediğinde devasa boyutlarda, çok fazla çeşitli değişkenler altında, yapılandırılmamış ve anlamsız bilgiler içermektedir (Ghemawat vd., 2003). Yüksek teknoloji içeren sistemlerden elde edilen bu tür verileri işlemek geleneksel analiz yöntemleri ile mümkün olmamaktadır. Bu nedenle daha öncede belirtildiği gibi büyük verilerin analizleri de üreten sistemler gibi yapay zekâ destekli programlar ve geliştirilmiş yeni yöntemler ile olmaktadır. Makine öğrenmesi ve derin öğrenme günümüzde bu anlamda en çok kullanılan yöntemlerin başında gelmektedir.

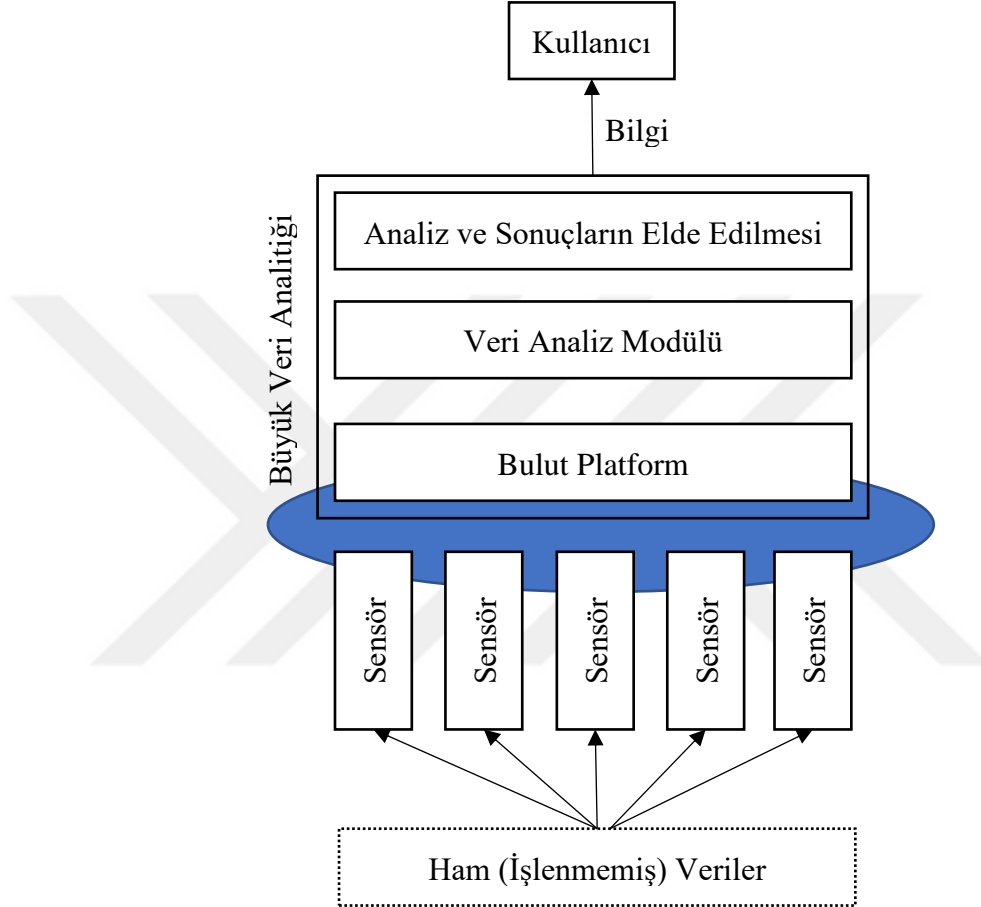
Wamba vd. (2015)'e göre ise büyük veri analitiği kullanan işletmeler; şeffaflık, eş anlı ihtiyaçları belirleme, süreçte yaşanan değişimleri fark edebilme, sürekli iyileştirmeyi sağlama, yeni stratejiler ve ürünler geliştirme avantajlarına sahiptir. Bunlara ek olarak hastanelerde hastalık tahmini, hasta veri yönetimi ve genetik programlama (Khan vd., 2012; Shakil vd., 2020); eğitim alanında eğitimi geliştirmek, öğrenci başarı seviyesi tahmini yapmak (Khanna vd., 2016) gibi büyük veri analizinin avantajları ve uygulama alanları bulunmaktadır. Büyük veri analitiği oldukça karmaşık bir süreç olarak tanımlansa da genellikle beş temel adımda uygulanmaktadır (Almaslamani vd., 2020):



Şekil 1. 1. Büyük Veri Analitiğinin Temel Aşamaları

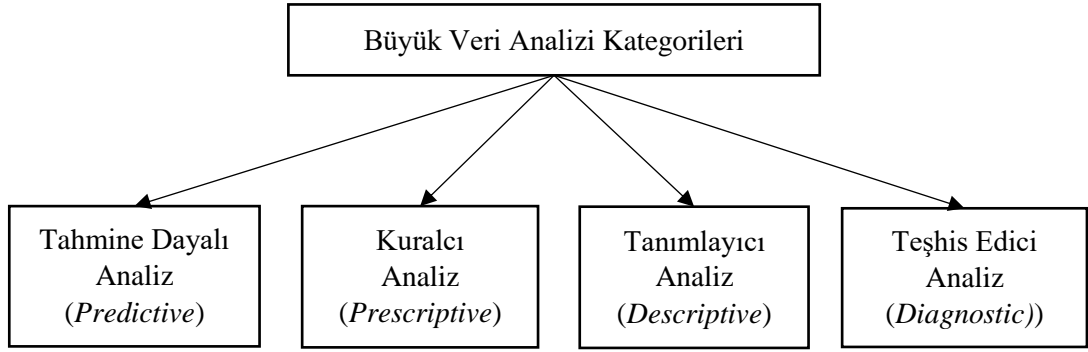
Kaynak: Almaslamani vd., 2020

Büyük veri analitiğinde sensörler, nesnelerin interneti ve diğer kaynaklar aracılığıyla elde edilen veriler bir bulut depolama sisteminde depolanmaktadır. Depolanan bu ham veriler önce ayrıştırılarak yapılandırılmakta devamında analiz edilerek faydalı bilgilere dönüştürülmektedir. Bu akışın bir şema olarak gösterimi şu şekildedir (Tsai vd., 2015):



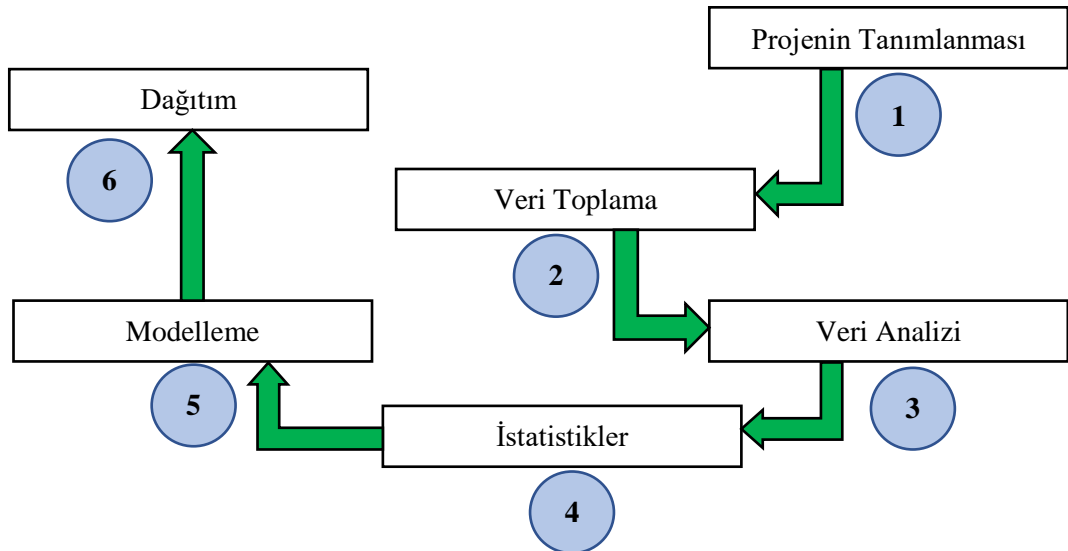
Şekil 1. 2. Büyük Veri Analitiği Sistemi

Endüstri 4.0'ın iş süreçlerini dijitalleştirdiği bu dönemde süreçler içerisinde elde edilen büyük verilerin, büyük veri analitiği sisteminin gösterildiği şekilde olduğu gibi analiz edilerek anlamlı sonuçlar içermesi tedarik zinciri yönetiminin sahip olduğu fonksiyonların başarılı olarak işlemesi için önemlidir. Dijital çağ olarak adlandırılan bu dönemde büyük veri analizi tahmine dayalı, kuralcı, tanımlayıcı (Lamba ve Dubey, 2015) ve teşhis edici (Dai vd., 2020) olmak üzere dört temel kategoride ele alınmaktadır:



Şekil 1. 3. Büyük Veri Analitiği Kategorileri

Tahmine dayalı analiz, geçmişte gerçekleştirilen faaliyetlere dair verileri kullanarak gelecekteki muhtemel sonuçları tahmin etmek için kullanılan, makine öğrenimi temelli bir analiz türüdür (Kaliraj ve Devi, 2022). Bir başka ifade ile işletmelerin elinde bulunan büyük verilerin analiz edilerek, genellikle tarihsel ve işlemsel verilerin kullanılarak risk ve fırsatların belirlenmesinin amaçlandığı, bu yol ile tahminler yapmayı olanaklı kılan büyük veri analizi çeşididir. Tahmine dayalı büyük veri analizleri ile işletmeler, stratejik planlarını sağlam bir temele oturtma olanağına sahip olurlar. Büyük verilerin kullanılarak, geleneksel karar verme yöntemlerinin yerine kullanılması alınacak kararların ve yapılan planların başarısını doğrudan etkilemektedir. Tahmine dayalı büyük veri analizi süreci Şekil 1.13'te sunulmuştur (Chaudhary ve Alam, 2022):



Şekil 1. 4. Tahmine Dayalı (Predictive) Analiz Süreci

Kaynak: Chaudhary ve Alam, 2022

Tahmine dayalı büyük veri analitiđi, tüketici davranışlarını tahmin etmek gibi basit problemlere uygulanabileceđi gibi bir bireyin kan tahlili sonucuna göre kanser olma olasılıđının hesaplanması gibi karmaşık ve çok boyutlu problemlerde de uygulanabilmektedir. Teknolojinin kullanımı ve gelişimi ile beraber, yapay zekâ aracılığıyla sahip olunan veri miktarının artması tahmine dayalı analizlerin çok deđişkenli ve büyük veriler ile yapılmasını olanaklı kılmıştır. Bu durumda doğrudan yapılan analizlerin hızını, kalitesini, doğruluđunu ve başarısını etkilemektedir (Chaudhary ve Alam, 2022).

Tahmine dayalı büyük veri analitiđi tüm analitik türleri içerisinde işletmelere en fazla zeka ve deđer getirme yeteneđine sahip olan, en gelişmiş analitik türüdür (Šikšnys vd., 2016).

Kuralcı analitik, işletme tarafından belirlenmiş bir senaryoya ya da plana göre gerçekleştirilebilecek olası planlar içerisinde en iyisinin belirlenmesini amaçlayan büyük veri analitiđi türüdür. Bu büyük veri analitiđi türünde tahmine dayalı analitikten farklı olarak direkt olarak bir sonucu tahmin etme durumu yerine, belirlenmiş bir senaryo için en uygun ya da başarılı olacak sonucun planlanması için bir strateji sağlar. Kuralcı analitik, herhangi bir şekilde insan müdahalesi gerektirmeden, otonom olarak makine öğrenmesi ve derin öğrenme gibi yapay zekâ tekniklerine dayanan analitik türüdür (Chaudhary ve Alam, 2022).

Tanımlayıcı ya da betimleyici analitikte, herhangi bir işletmede neler olduđu sorusunun cevabının ortaya çıkarılmaya çalışıldıđı genellikle tahmine dayalı ya da kuralcı analitik ile beraber kullanılan en temel analitik biçimlerinden biridir. Bu analitik türünde, belirli bir dönemde ele alınan işletmede neler olduđu ve bir başka dönemden hangi noktalarda farklılaştıđını belirlemek amacıyla büyük veri kullanılmaktadır. İşletme yöneticileri, geçmiş bir dönemlere ait verilere dayanarak tanımlayıcı analitiđi kullanmaktadırlar. Bu yolla temel alabilecekleri bir trende sahip olarak stratejiler gerçekleştirmektedirler (Chaudhary ve Alam, 2022).

Teşhis edici analitik, tanımlayıcı analitiđin ne sorusunun aksine neden sorusunun sorularak cevap arandıđı, genellikle işletmelerde iş analitiđinin ilk aşamasını oluşturan

analitik türüdür. Bu analitik türünde veriler detaylı olarak incelenerek, gizli kalmış çıkarımlar araştırılmaktadır. Bu analitik türünde diğer analitiklerden farklı olarak herhangi bir sonuç üretilmez. Eldeki sonuçlar yerine bu analitik türünde o sonuçların arkasındaki nedenler araştırılmaktadır. Teşhis edici analitik sürecinde veri keşfi, veri madenciliği ve ayrıntılı inceleme gibi teknikler kullanılmaktadır. Kullanılan teknikler ile beraber oldukça karmaşık olan veriler, herkesin anlayacağı ve kullanabileceği şekilde iç görüşlere dönüştürülmekte ve görselleştirilerek sunulmaktadır (Chaudhary ve Alam, 2022). Bahsedilen veri analizi kategorileri ve karşılaştırılması Tablo 1.3'te sunulmuştur.

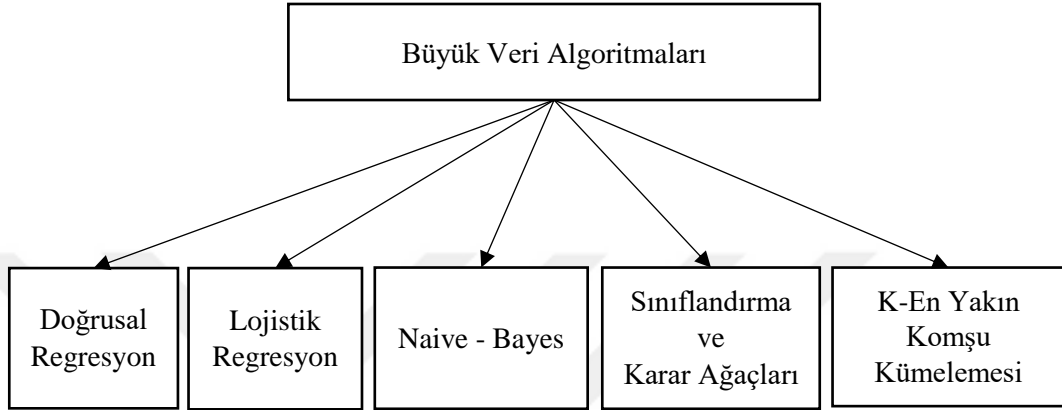
Tablo 1. 3. Veri Analizi Kategorilerinin Farkları ve Karşılaştırması

Sınıflandırma Kategorisi	Tahmine Dayalı	Kuralcı	Tanımlayıcı	Teşhis Edici
<i>Veri Kaynağı</i>	Geçmiş veriler kullanılır.			
<i>Veri Manipülasyonu</i>	Mevcut verilerdeki boşluklar doldurulur.	Değişkenlere dayalı sonuçları tahmin eder.	Veriler okunması kolay bir biçimde yeniden yapılandırılır.	Tanımlanan Kusurlar.
<i>Analizin Rolü</i>	Veri modelleri oluşturur.	Sonuçlar hakkında öneriler sunar.	İş operasyonunun durumunu açıklar.	Veri trendlerini vurgular.
<i>Kullanılan Teknik</i>	Potansiyel gelecekteki sonuçları tahmin eder.	Algoritmalar, makine öğrenimi ve yapay zekâ kullanır.	Geçmişten ders alır.	Altta yatan sorunları araştırır.
<i>Cevaplanan Sorular</i>	Ne olabilir?	Ne yapmalıyız?	Ne?	Niçin?

Günümüzde işletmeler veri biliminin gücünü keşfederek, büyük veri analizi için departmanlar kurmakta ve büyük miktarda kaynak ayırmaktadırlar. İşletmelerin elinde iş süreçlerine dair devasa verilerin olması ve bu verilerin işlenerek anlamlı sonuçlar çıkarılması, işletmelerin teknolojinin sınırlarını zorlamasına neden olmuştur. Bu kapsamda veri analizleri tüm süreçlere yansıtılmakta ve işletme politikaları elde edilen sonuçlar neticesinde oluşturulmaktadır.

Büyük verilerin elde edilmesi, klasik veri analizlerini basit ve etkisiz kılmış; daha hızlı ve doğru sonuçlar veren algoritmalar geliştirilmiştir. Yapılan bilimsel

çalıřmalarda birok byk veri analitięi algoritması geliřtirilmiř ve halen geliřtirilmeye devam etmektedir. Bu nedenle tm algoritmaları aıklamak mmkn olmadığı iin Őekil 1.14'te gsterilen en yaygın olarak kullanılan beř algoritma bu kısımda aıklanacaktır.



Őekil 1. 5. Byk Veri Analitięi Algoritmaları

Kaynak: (Chaudhary ve Alam, 2022)

Byk veri analizinde kullanılan algoritmalar makine ęrenmesinde de yaygın olarak kullanılmaktadır. Bu nedenle bu kısımda sz konusu algoritmaların aıklanması makine ęrenmesi bařlıęına bırakılmıřtır.

1.3. MAKİNE ęRENMESİ

2000'li yıllarda bilgisayarların ucuzlařarak eriřilebilir olması; akıllı telefonların ve tabletlerin hızla geliřerek hayatımıza girmesi; internet altyapısının geliřerek internetin kablolu ve kablosuz bir Őekilde evlerimize ve akıllı telefonlar aracılıęıyla cebimize girmesi teknolojiyi ayrı bir seviyeye getirmiřtir.

Geleneksel olarak uygulanmakta olan teknikler, ara ve gereler, rnler ve hizmetler bu geliřmelere baęlı olarak dijitalleřmeye bařlamıřtır. Bugn lkemizde 6754 adet resmi hizmeti e-devlet zerinden yapıyor olmamız (<https://www.turkiye.gov.tr/edevlet-istatistikleri?hizmet=Istatistikleri>) ve akıllı elektronik cihazlar buna en gzel rnektir.

Dijital alanda yaşanan gelişmelerin ana kaynaklarından biriside teknolojiye yaşanan gelişmelerin yanında veri depolarının icat edilmesidir. 1960'lı yıllarda ortaya çıkan veri depoları; veriyi dijital ortamlarda bulunan bilgileri herhangi bir harici depolama aleti olmadan ve bilgisayar ya da diğer cihazlarımız kapasite bile saklamamızı sağlayan programlar olarak karşımıza çıkmaktadır (Alpaydın, 2019).

İlk icat edildiğinde yalnızca hesap makineleri olarak görülen bilgisayarlar, günümüzde veriyi depolamanın yanında, karmaşık problemleri çözebilen ve öğrenerek düşünebilen birer akıllı makine haline gelmiştir. İlk bilgisayar olan ENIAC (Say, 2018)'tan günümüz gelişmiş bilgisayarlarına doğru geldikçe, bilgisayarların düşünebilen ve mevcut veri ile yeni bir ürün, hizmet veya modeller geliştiren aygıtlar olduğunu görmekteyiz. Endüstri 4.0 ile birlikte geri dönülemez ve oldukça hızla gelişen teknoloji ile beraber hayatımıza giren Endüstri 4.0 bileşenleri ve özellikle internete sahip nesnelere (IoT) ve bulut bilişim veri üretimi ve depolanması hususlarında veri bilimine ayrı bir boyut kazandırmıştır. Artık internet bağlantısına sahip ve sensör içeren makineler kendi verilerini anlık olarak üretmekte ve bulut bilişim sayesinde internet üzerinden depolanmaktadır. Bu durum büyük veri kavramını iş süreçlerinde ve sayısal analizlerde önemli bir odak noktası haline getirmiş ve rekabet edebilmek ve her türlü kararı etkin bir şekilde alabilmenin yolu bu verileri analiz etmeye bağlı olmuştur. Yapay zekâ (AI) terimi ise, 1956'da Dartmouth College'daki bir atölyede bilgisayar bilimcisi ve yapay zekânın kurucusu sayılan John McCarthy tarafından ilk kez ifade edilmiştir (Jiang, 2021).

Yapay zekâ tabanlı bu makinelerin ürettiği ve yine yapay zekâ ile arşivlenen bu verilerin depolanması da yine yapay zeka tabanlı uygulamalar ile olmaktadır. Bu nokta da büyük verileri analiz etme de kullanılan yöntemlerin başında makine öğrenmesi gelmektedir. Artık sadece kendi bilgisayarlarımızda değil, internete sahip her bir bireyin bilgisayarında olan ve paylaştığı verilere internet üzerinden erişerek analizleri bu yolla yapmamız mümkündür.

20. yüzyılın sonlarında teknolojinin gelişmesi ile beraber batarya teknolojisinde de önemli gelişmeler yaşanmıştır (Jayaseelan, 2006). Bu gelişmeler bilgisayarları elektrik bağlantısı olmasa da bataryalar ile kullanabilmemizi sağlayarak teknoloji alanında

devrim niteliğinde bir gelişmeye sebep olmuştur. Gelişen yeni bataryaların taşınabilir bilgisayarlar ve cep telefonlarımızda kullanılması; takip eden süreçte 2005 yılında ilk dokunmatik ekranlı cep telefonunun icat edilmesiyle beraber (Alpaydın, 2019), geri dönüşü olmayan ve oldukça hızlı gelişen dijital çağa girmemize sebep olmuştur. İnternetin yaygınlaşması, batarya teknolojisinin gelişmesi ve bilgisayarların gelişerek taşınabilir hale gelmesiyle birlikte, içerisinde bulunduğumuz dijital çağda teknoloji ve bileşenleri ışık hızında gelişmeye devam etmektedir. Artık elimizde olan ve cebimizde taşıdığımız, dokunmatik ekran ve yüksek batarya özelliklerine sahip akıllı cep telefonlarımızı bu teknoloji çağında birer bilgisayar olarak kullanmaya başladığımız görülmektedir. Akıllı telefonlarımız aracılığıyla gerek mobil uygulamalar gerekse de internet üzerinden birçok iş ve işlemi kolaylıkla yapabilmekte, depolaya bilmekte ve paylaşabilmekteyiz.

Teknolojide yaşanan gelişmeler ile beraber yazılım ve programlama dilinde yaşanan gelişmeler yapay zekâ tabanlı uygulamaları hayatımıza sokmuştur. Yapay zekâ tabanlı olan ve makine öğrenmesine dayanan siri ve google asistan gibi yardımcılardan cep telefonlarımıza girmesi, cep telefonlarımızda yaptığımız işlemlerin her birinin depolanması sürekli olarak birer veri kaynağı haline gelmemize neden olmuştur. Bir diğer yandan, cep telefonlarımızda yaptığımız her bir tıklama ve her bir işlemin bir veri olarak işlenmesi ve yine yapay zekâ içeren bu telefonların makine öğrenmesi yöntemleri ile bize öneriler getirmesine neden olmuştur.

Yapay zekâ, büyük veri ve makine öğrenmesinin hayatımıza bu kadar yüksek bir hızla girerek farkında olmasak da entegre olması, bu konuyu birçok farklı alanda incelemeyi zorunlu hale getirmiştir. Tedarik zincirleri de Covid-19 pandemisi ile beraber dijitalleşen ve büyük veri analitiğine sahip bir alandır. Günümüzde işletmelerin ana problemlerinden ve en çok zaman harcadığı konulardan birisi tedarik zinciri yönetimleri haline gelmiştir. Yapay zekâ uygulamaları, bulut bilişim ve sensörlerin yaygın olarak kullanılarak elde edilen büyük verilerin analiz edilmesi de yine yapay zekâ desteği ile mümkün olmaktadır. Bu noktada geliştirilen makine öğrenmesi algoritmaları büyük verilerin analiz edilmesinde etkin ve verimli bir şekilde kullanılan algoritmalarlardır. Bu bakımdan literatürde oldukça kısıtlı bir yer bulan IoT tabanlı

tedarik zincirlerinin sahip olduđu büyük verilere dair analizlerin makine öğrenmesi ile yapılması konusu bu tez çalışması kapsamında ele alınmaktadır.

Belirtilen neden ile tez çalışmasının uygulama metodolojisi olarak belirlenen makine öğrenmesi konusu bu başlık altında detaylarıyla ele alınacaktır.

1.3.1. Makine Öğrenmesi Kavramı

Günümüzde müşteri davranışları, birçok faktöre bağılı olarak deęişiklik göstermektedir. Zaman içinde sürekli olarak demografik, coğrafi, cinsiyet ve eğitim seviyesi gibi faktörlere bağılı olarak deęişebilen bu tercihler karşısında işletmeler sürekli olarak bu faktörlere dair verileri elde etmek, izlemek, işlemek ve deęerlendirerek; ürün ve hizmet üretim süreçlerine entegre etmektedir. Yani tüketicilerine dair verileri faydalı bilgilere dönüştürmeye çalışmaktadır. Bunu yaparken işletmeler artık makine öğrenmesi algoritmalarını kullanarak tahminler yürütmektedir. Dinamik bir yapıya sahip olarak sürekli deęişen bu tahminler, üretilecek ürün ve hizmetlerde deęişikliklere neden olacağı için tedarik zincirleri açısından konunun ele alınması ve hem dinamik hem de akıllı zincirlerin tasarlanması gerekmektedir.

Öğrenme yeteneđi, zekânın temel özelliklerinden biridir (Langley, 2016). İnsanođlu, doğduğumuz günden itibaren çevre ile olan etkileşimleri yoluyla öğrenmeye programlanmıştır. Bu doğrultuda insanođlu, tarih boyunca ihtiyaçlarını karşılamanın zorluklarıyla başa çıkmak için çeşitli araçlar icat etme ve geliştirme mücadelesi vermiştir. Yaratıcı problem çözme becerileri olarak ifade edilen zekânın ürünü olan bazı icatlar, ihtiyaçları karşılamanın çok ötesinde bir etkiye sahip olmuş, hatta yaşam biçimimizi etkilemiştir. Alanında öncü bir Amerikalı bilgisayar bilimcisi olan John McCarthy'nin "akıllı makineler yapmanın bilimi ve mühendisliđi" olarak tanımladıđı "yapay zekâ" kavramı ilk kez 1956 yılında "Dartmouth College Yapay Zekâ Konferansı'nda kullanılmıştır (Moor 2006).

Yapay Zekanın ilk örnekleri, klasik programlama yaklaşımları ile problem odaklı, spesifik çözümler üretebilmiştir (Brewer, 2000). Dünya genelinde dijitalleşmenin yaşanması, bilgi teknolojileri, robotik uygulamalar, iletişim teknolojisi ve yapay

zekânın gelişmesiyle birlikte, dördüncü sanayi devrimi olarak ifade edilen bir çağ yaşanmaktadır. Bu dönemde makinelerin, insan gibi düşünerek karar verme zekâsı kazanması gibi ayırt edici bir özelliğinin olması üzerinde çalışmalar yapılmaktadır (Gupta vd. 2017). Gerçekleştirilen bu çalışmalar incelendiğinde, makinelerin birçok konuda, insanlardan daha doğru sonuçlar verebildiği ortaya konmuş ve hatta onların yerini makine öğrenmesi algoritmalarıyla almaya başlamıştır (Marr, 2016).

Yapay zekâ kullanılarak çevresindeki durumları algılayarak tepki verebilen insan beyni benzeri çalışma prensipleri olan makineler geliştirilmektedir. Ancak insan beyninin tam olarak nasıl çalıştığını bilmediğimiz, koşulların değişken olduğu ve net bir şekilde tanımlanamadığı alanlarda program geliştirmenin oldukça zor olduğu gerçeği ortadadır (Hinton, 2013).

Yapay zekâ içeren uygulamalardan elde edilen makine öğrenmesi ise, yirminci yüzyılın son çeyreğinde gerçekleştirilen örüntü tanıma araştırmalarına dayanmaktadır. İlk olarak bu yol ile ortaya çıkan makine öğrenmesi, teknolojinin yetersiz olmasından dolayı uzun bir süre gelişmemiştir (Bishop, 2006). Son dönemde ise endüstri 4.0 ile birlikte teknolojide yaşanan hızlı gelişmeler, makine öğreniminin hızla gelişmesine ve yaygın olarak kullanılmasına neden olmuştur. Geliştirilen yeni teknikler ve yüksek yetenekli bilgisayarlar ile yazılım mühendislerinin karmaşık algoritmalarla çalışması mümkün hale gelmiştir. Bu durumda makine öğrenmesini geliştiren nedenlerin başında gelmektedir. Bilgisayar programlamada yaşanan gelişmeler, bilgisayar teknolojisinin gelişmesi ve internetin yaygınlaşmasıyla beraber veri madenciliğinin ortaya çıkması, makine öğrenmesinin gelişimini sağlamıştır (Hoppe, 2019).

Makine Öğrenmesi literatürde ilk kez 1959 yılında Arthur Lee Samuel tarafından “*Some Studies In Machine Learning Using The Game of Checkers*” isimli çalışmasında kullanılmış ve yapay zekânın bir alt alanı olarak tanımlanmıştır. Samuel makine öğrenmesini, bilgisayarların programcılarının tekrar yazılımda değişiklik yapmasına gerek olmadan işlemlerini yapabilmesini sağlayan bilim dalı olarak ifade etmiştir (Samuel, 1959). Tjahjono vd. (2017) ise makine öğrenimini, doğrudan insan müdahalesi olmadığı için veri yorumlamanın olumsuz etkisini azaltmaya yardımcı olan bir araç olarak tanımlamıştır. Bu tanımdan yola çıkarak, makine öğrenmesinin

genellikle büyük veri setini sisteme girdi olarak dâhil ederek, endüstrilerin güncel taleplerine hızlı bir şekilde cevap vermesine olanak tanıdığı anlaşılmaktadır (Tjahjono vd. 2017).

Makine öğrenimi günümüzde birçok alanda yaygın olarak kullanılmaktadır. Tedarik zinciri yönetiminde ise içerdiği karmaşık yapıdan dolayı sürece dair verilerin makine öğrenmesi yöntemleri ile analiz edilerek politikalara dönüştürülmesi, tedarik zincirlerinin başarısını doğrudan etkilemektedir. Bu bakımdan makine öğrenmesi tedarik zinciri alanında yaygın olarak kullanılmaktadır.

Geçmişten günümüze tedarik zinciri kavramının gelişmesi ve özellikle Endüstri 4.0'ın etkileri ile tedarikçi seçiminde dikkat edilmesi gereken noktalar değişmiş; geleneksel yaklaşımlarda uygun fiyat, istenen kalite ve yakın mesafe gibi birkaç kriter aranırken, günümüzde tedarikçi seçimi başlı başına bir süreç haline gelmiş ve tedarikçiler için kriterler artmıştır (Paksoy vd., 2021). Birçok faktöre sahip bir sistem haline gelen tedarik zincirlerinde, belirsizlik için karar verme ihtiyacı önemli bir konu haline gelmiştir (Hult vd., 2010). Tedarik zincirini belirsiz çevre koşullarında ele alırken, gelecek tahmini ve tahminin güvenilirliği önemli bir sorun haline gelmektedir (Spekman vd., 2002). Günümüzde, uzun vadeli perspektifte ele alındığında tedarik zincirleri üzerinde daha fazla kontrol sahibi olmak bir zorunluluk haline gelmiştir (Sucky, 2005). Bu noktadan hareketle makine öğrenmesi ile büyük veri analizinin, tedarik zincirleri için oldukça önemli bir konu olduğu aşikârdır.

Tedarik zinciri yönetiminin yanı sıra mal ve hizmet akışlarında karar verme süreci, birçok karmaşık karar verme sürecini ve bilgi engellerini içermektedir. Makine öğrenmesi ile geleneksel yöntemler karşılaştırıldığında birtakım üstünlükleri vardır (Ni vd. 2019):

- Makine öğrenmesi algoritmaları tedarik zincirlerinde, doğrusal olmayan ilişkileri açıklayabilmesi noktasında geleneksel yaklaşımlara göre büyük bir avantaj sağlamaktadır.
- Makine öğrenmesi, geleneksel modellerin başarısız olduğu durumlarda yapılandırılmamış veri kümeleriyle başa çıkabilen algoritmaları içermektedir.

- Makine öğrenimi ve temel yapıları, daha iyi bir tedarik zinciri yönetimi için performans tahmini yapmada doğru ve etkin sonuçlar vermektedir.
- Makine öğrenimi, tedarik zinciri performansını en çok belirleyen temel faktörleri sürekli olarak aramada son derece seçici bir yaklaşım sunmaktadır.
- Makine öğrenmesi, fiziksel varlıkların bakımı ve fiziksel incelemede birçok potansiyel uygulamayı keşfedebilmektedir.

Bugüne kadar yapılan çalışmalar neticesinde geliştirilen makine öğrenmesi algoritmalarından istenen, sahip olunan veriler arasında bulunan açık ilişkilerin yanında örtük yani bilinmeyen bağlantıları ortaya çıkarmaktır. Bu yol ile problemin çözümüne yönelik bir model geliştirerek genelleme yapılmakta, yeni durumlar için doğru sonuçlar üretilmektedir. Makine öğrenmesi bu doğrultuda kümeleme, sınıflandırma, regresyon ve tahmin gibi görevleri yerine getirebilmek amacıyla hesaplamalı istatistik, matematiksel optimizasyon, olasılık teorisi ve veri madenciliği ile yakından ilişkilidir (Kıran vd. 2021).

Makine öğrenmesi terimi açıklanmadan önce, öğrenme kavramının ve makine öğrenmesi kavramının tanımlanması konunun anlaşılması bakımından önemlidir. Öğrenme kelimesinin sözcük anlamı; öğrenim, talimat ve deneyim yoluyla beceri, anlama ve bilgi kazanımı olarak tanımlanmaktadır (Nilson,1996). Makine öğrenmesi, geliştirilen sistemin önceki dönemlerde elde ettiği tecrübelerine dayanarak oluşturulacak model ile sonraki dönemlere dair tahminler yapmasını olanaklı kılan, yapay zekâ tabanlı yöntemlerdir. Bir başka ifade ile makine öğrenmesi, temel olarak geçmişteki durum ve olaylardan elde edilen bilgilerden yola çıkarak gelecekteki muhtemel benzer olaylar üzerinde geçmişe benzetilerek tahminler yapmayı olanaklı kılan disiplindir. Kısaca ifade edilecek olursa makine öğrenmesi, deneyimlerden öğrenen bilgisayar algoritmalarının geliştirilmesi ve uygulanmasıyla ilgilenen bu tekniklerden biridir (Mitchell, 1997).

Makine öğrenmesi, veri madenciliğiyle yakın ilişkili olarak geliştirilen, bilgisayarların bireylerin düşünce yapısına benzer bir şekilde öğrenmelerine yönelik yöntemleri içeren bilim alanıdır (Kavakiotis vd., 2017). Makine öğrenmesinin veri madenciliğinden farkı, veri madenciliğinin daha kapsamlı araştırmalar yapmasıdır.

Sözelimi, makine öğrenmesi; veri madenciliğinin uygulanmasını olanaklı kılmaktadır. Makine öğrenmesi büyük veri tabanlarında uygulandığında, gerçekleştirilen uygulamalar veri madenciliğini oluşturmaktadır (Mitchell, 1999).


Bir yapay zeka uygulama alanı olan makine öğrenmesinin (Helm vd., 2020) amacı, daha kesin tahminlerde bulunarak daha olumlu sonuçlar elde etmektir. Makine öğrenimi teknikleri büyük ölçüde bilgi işlem gücüne dayanmaktadır. Bunu yapabilen algoritmalar oluşturmak, bilgisayarların ikili evet ve hayır mantığını kullanması makine öğreniminin temelini oluşturmaktadır (Jabbar vd., 2018). Mevcut olan herhangi bir problemi makine öğrenimi algoritmalarıyla çözmek için girdilerin ve çıktılarının ne olduğunu anlamak önemlidir. Örneğin, bir konuşma tanıma probleminde, sistemin girişi bir mikروفon tarafından yakalanan konuşma sinyalleridir ve çıktı ise, sinyallere gömülü olan kelimeler ya da cümlelerdir. İngilizce'den Fransızca'ya makine çevirisi probleminde, girdi İngilizce metin belgesiyken çıktı ise karşılık gelen Fransızca çeviridir (Jiang, 2021).

1.3.2. Makine Öğrenmesi Aşamaları

Makine öğrenmesi yönteminin uygulanması için kabul edilen bir takım sıralı aşama bulunmaktadır. Makine öğrenmesi uygulamalarında takip edilebilecek aşamalar Şekil 16'da özetlenmiştir. İşlemler açısından makine öğrenmesi verilerin hazırlanması ile başlamaktadır. Bu aşamada verilerin doğruluğu, sayısı, seçimi gibi adımlar içerebileceği gibi makine öğrenmesi algoritmaları öğrenme yöntemlerine göre farklılık gösterebilmektedir. Eğitim verisi ana verinin içinden çekilen örnekler aracılığı ile oluşturulmaktadır. Genellikle veri setinin %70'i eğitim kalan %30'u ise test için kullanılmaktadır. Eğitim veri seti, algoritmanın öğrenme sırasında kullandığı maliyet fonksiyonunu minimize etmek için kullanılmaktadır (Zhang vd., 2020). Seçilen eğitim tekniği ve parametre ayarları ile seçilen model çalıştırılarak, gerekli görülen durumlarda parametreler güncellenerek beklenen sonuçlar elde edilene veya daha fazla iyileşme sağlanamadığı ortaya çıkana kadar model tekrar çalıştırılmaktadır. Nihai seçim, belirlenmiş performans metriklerine göre en uygun sonucu veren model olacaktır (Daldır, 2021). Makine öğrenmesi uygulanırken Şekil 1.15'te gösterilen beş temel aşama uygulanmaktadır (Bilgin, 2018):

1. Verilerin Toplanması

2. Verilerin Analizlere Hazırlanması
3. Modelin Eğitilmesi
4. Modelin ve Sonuçların Değerlendirilmesi
5. Performansın Arttırılması



Şekil 1. 6. Makine Öğrenmesi Aşamaları

Makine öğrenmesi uygulamalarının ilk aşaması olan *verilerin toplanması* aşamasında ham veriler elde edilir. Geleceğe yönelik doğru tahminler yapabilmek için ham verilerin çeşitli değişkenlere dair, doğru ve yeterli olması makine öğreniminin gerçekleşmesi için önemlidir. *Verilerin analizlere hazırlanması* aşamasında ise elde edilen verilerin işleme alınmadan önce ön işleme tabi tutularak temizlenmesi, hataların düzeltilmesi ve sınıflandırılması gibi işlemler yapılır. *Modelin eğitilmesi* aşamasında ise elde edilen veri setine ve amaca uygun algoritmanın belirlenerek, modelin eğitilmesi gerçekleştirilir. Bu aşamada veriler test verisi ve eğitim verisi olarak sınıflara ayrılmaktadır. *Modelin ve sonuçların değerlendirilmesi* aşamasında bir önceki adımda belirlenen model yürütülerek sonuçlar elde edilir. Bu aşamaya modelin test edilmesi aşaması denmektedir. Son aşama olan *performansın arttırılması* aşamasında ise kullanılan modelden farklı bir model seçerek daha fazla ya da farklı veriler ile tekrar model test edilerek en iyi performansa erişilecek modelin geliştirilmesine çalışılır (Bilgin, 2018).

Makine öğrenmesi algoritmaları kullanılarak özellik seçimi ve çıkarımı, ilişkilerin belirlenmesi ve veri ayrıklaştırma gibi işlemler yapılmaktadır:

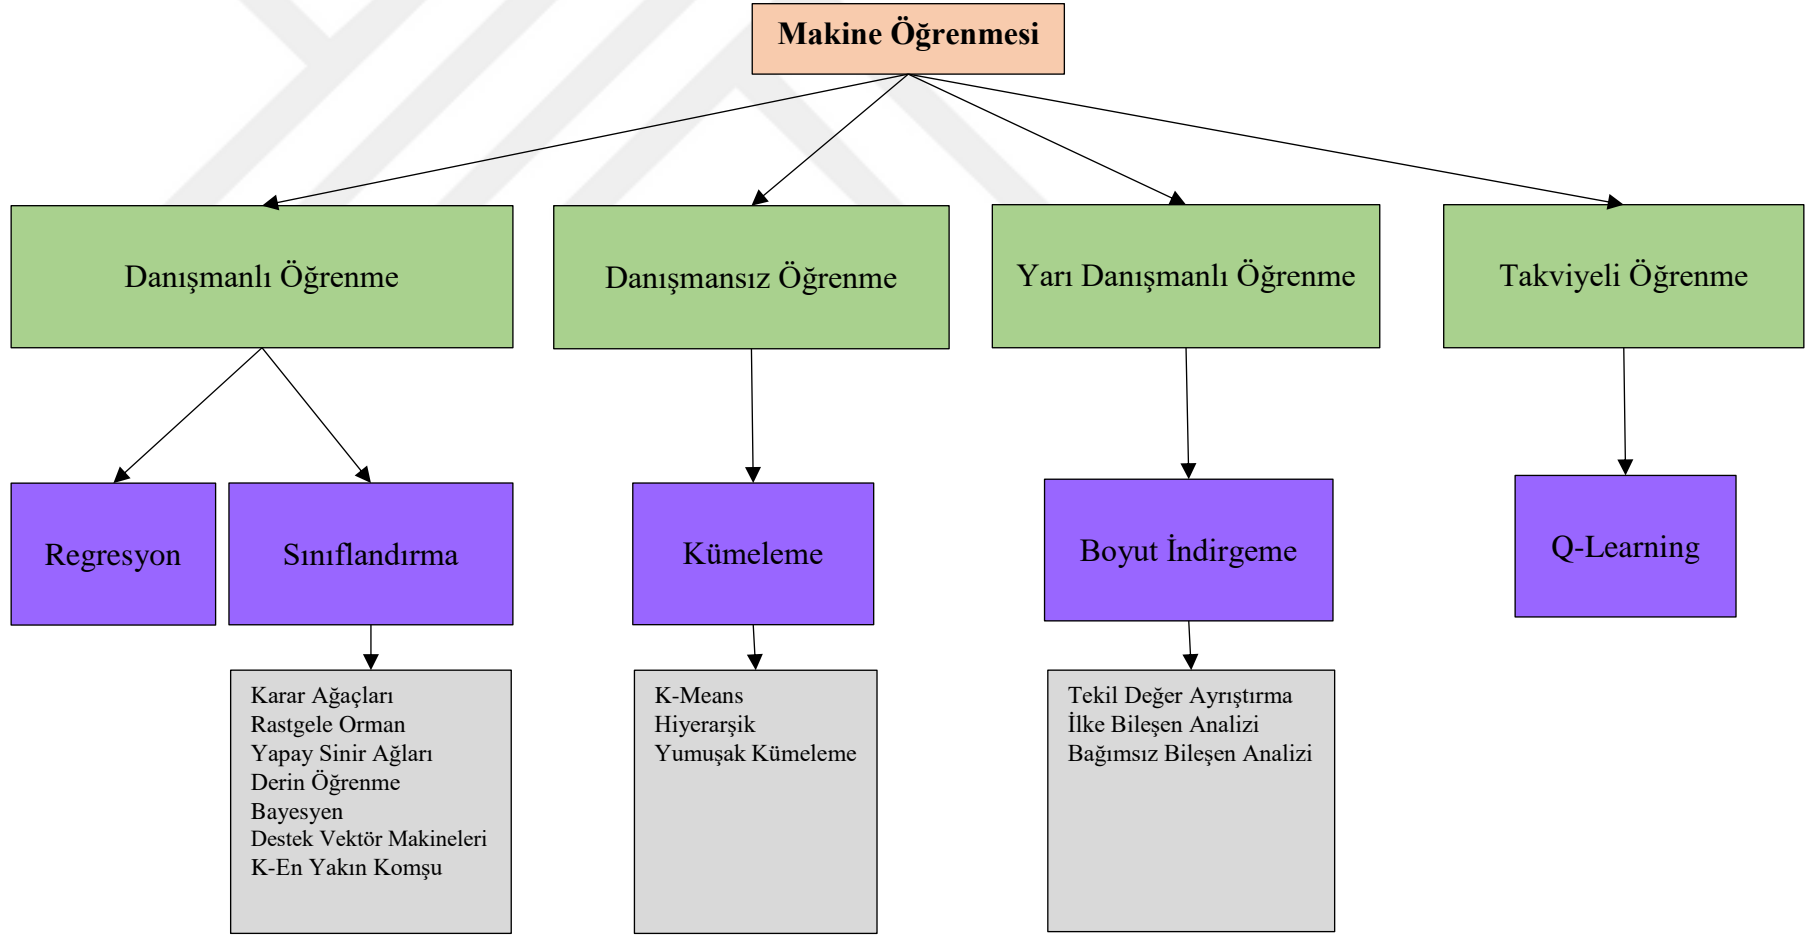
- **Özellik Seçimi ve Çıkarımı:** Elimizdeki verilere ait birçok özellikten, verinin kümesini/sınıfını/değerini belirleyen özelliklerinin hangileri olduğu bilinmeyebilir. Bu tarz durumlarda elimizdeki veriye ait tüm özellik kümesinin bir alt kümesi seçilir ya da bu özelliklerin birleşimlerinden yeni özellikler elde

edilir (özellik çıkarımı). Bunu yapmanın amacı, hesaplama yükünü azaltırken başarı oranını yükseltmektir (Amasyalı, 2008).

- **İlişkiyi Belirleme:** İlişki belirleme yöntemini bir örnek üzerinde anlatılacak olursa; bir süper markette M ürününü alan müşterilerden %90'ı N ürününü de alıyorsa, M ürününü alıp N ürününü almayan müşteriler, N ürününün potansiyel müşterileridir yorumu yapılabilir. Bu tarz durumlarda çözümlenmesinde ilişkiler belirlenmesi yöntemleri tercih edilmektedir (Bilgili, 2018).
- **Veri Ayırıklaştırma:** Veri ayırıklaştırma (Data Discretization) terimi, elimizdeki sayısal verilerin kategorik verilere dönüştürülmesi sürecine verilen isimdir. Sayısal verileri ayırıklaştırmak için sıklık dağılımları kullanılmaktadır. Bu işlem ile yapılan gruplamanın artışı ilgili verideki gürültünün azaltılmasını ve modelin kesinliğini artırmaktır. Ayırıklaştırma ile ayrıca eksik olan veya geçersiz olan değerlerinde elenmesi sağlanmaktadır (Koç, 2016).

1.3.3. Makine Öğrenmesi Metotları

Makine öğrenmesi üzerine yapılan çalışmalar sonucunda, makine öğrenmesi uygulamaları için geliştirilmiş yöntemler vardır. Literatürde danışmanlı, danımsız, yarı danışmanlı ve takviyeli öğrenme yolları olarak dört grupta bir sınıflandırma yapılmıştır. Bu sınıflandırmalar ve her sınıftaki metotlar derlenerek Şekil 1.16'da sunulmuştur (Kumar vd., 2019):



Şekil 1. 7. Makine Öğrenmesi Metotlarının Sınıflandırılması

1.3.3.1. Danışmanlı Öğrenme (Supervised Learning)

Geçmiş deneyimlerden öğrenmek, insanların bir özelliği iken, bilgisayarların bu yeteneği yoktur. Ancak günümüzde makine öğrenmesi algoritmaları ile makinelerde insanlar gibi deneyimleri kullanarak tahminler geliştirebilmektedir.

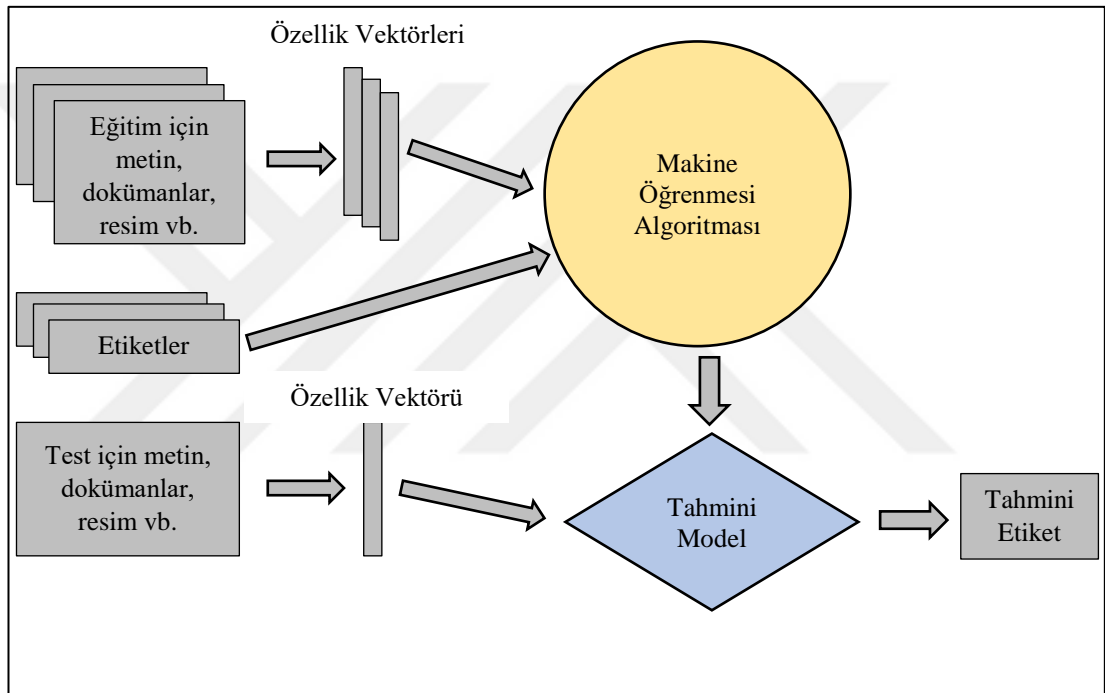
Danışmanlı veya denetimli makine öğreniminde ana hedefimiz, bir sınıfın değerlerini tahmin etmek için kullanılacak bir hedef işlevi öğrenmektir. Danışmanlı makine öğreniminde geçmiş dönemdeki mevcut veriler ile gelecekteki olası durumlar tahmin edilmeye çalışılmaktadır. Denetimli öğrenmede ilk adım veri kümesiyle uğraşmaktır. Veri seti üzerinde daha iyi bir eğitim ya da öğrenmek için uzman kişilerden yararlanılmaktadır. Eğer uygun bir uzman bulunamadığı takdirde eldeki ham veriler kabaca seçilmektedir. Fakat ön işleme tabi tutulmayan veriler, gürültülü ve eksik veri içerebileceği için gerçekleştirilecek tahminlerin doğruluğunu düşürmektedir (Kotsiantis vd., 2007). Veri seti belirlendikten sonra makine öğrenmesinde araştırmacının temel bir işlevi olan veri hazırlama ve veri ön işleme aşamasında veriler ön işleme yani ayrıştırmaya tabi tutulur. Kayıp, gürültülü ya da eksik veri varsa bu aşamada geliştirilen teknikler ile giderilmesi sağlanarak verilerin ön işleme adımı tamamlanmaktadır (Hodge ve Austin, 2004).

Danışmanlı Öğrenme, örüntünün bazı geçmiş verilere göre tanıdığı ve bu örüntülerin daha sonra gelecek tahminlerini desteklediği tekniktir. Geçmiş veriler girdi ve çıktı olarak çiftler halinde bulunur ve gelecekteki değerin tahmin edilmesinde kullanılırlar. Danışmanlı öğrenmenin, literatürde yaygın olarak regresyon ve sınıflandırma problemlerinde kullanıldığı ifade edilmektedir (Nasteski, 2017).

Danışmanlı öğrenmede (Supervised Learning) makine öğrenmesinin gerçekleşebilmesi için bir danışman atanmaktadır. Sisteme atanan danışman ele alınan probleme yönelik geçmiş örnekleri içeren girdi ve çıktı setlerini sisteme girmektedir. Danışman tarafından sisteme girilen bu veriler eşleştirilerek sistemin öğrenmesi sağlanmakta ve bu yol ile model oluşturulmaktadır (Nilsson, 1996). Modelin kurulmasında çıktıların ve girdilerin bilindiği veri setleri kullanılmaktadır. Kullanılan algoritma, örneklerin giriş vektörü ve çıkış vektörü tarafından tek tek beslenir. Zamanla, algoritma tüm örnekler için beklenen çıktıyı üretebilecek bir çözüm uzayı

üretir. Yani sisteme girilen eğitim örneğinde yer alan girdi ve çıktılara göre oluşturulan model test edilerek tahmin yapmak üzere kullanılabilir yapıya gelir (Paksoy vd. 2021).

Regresyon modelleri belirli iken sınıflandırma problemlerinde kullanılan danışmanlı öğrenme metotları arasında en yaygın kullanılanları Naïve Bayes sınıflandırıcı algoritması, destek vektör makinesi algoritması, karar ağaçları, rastgele ormanlar, derin öğrenme ve yapay sinir ağlarıdır (Makkar vd. 2020). Danışmanlı öğrenme Şekil 1.17’de görülmektedir.



Şekil 1. 8. Danışmanlı Öğrenme

Kaynak: Bilgin, 2018

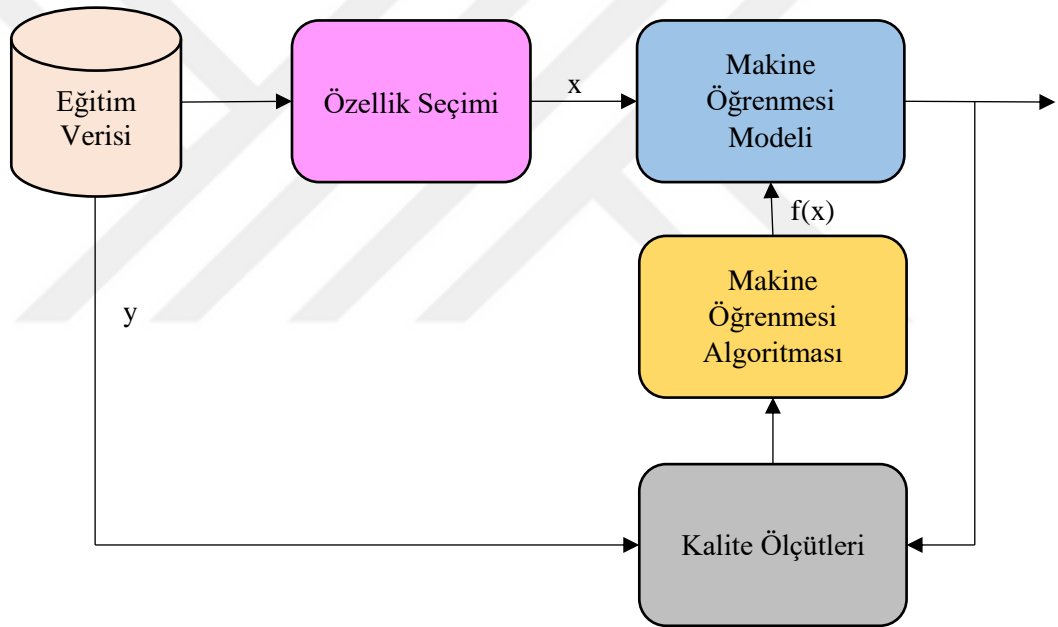
1.3.3.1.1. Regresyon

Regresyon kavramı ilk kez Francis Galton tarafından, bağımlı değişkenin birden fazla açıklayıcı değişkene bağımlı olduğu durumlar için kullanılan bir kavram olarak; ebevyenlerin boyu ile çocuklarının boyu arasındaki ilişkinin belirlenmeye çalışıldığı çalışmada ifade edilmiştir (Akın, 2013). Regresyon denetimli bir öğrenme yöntemidir ve belirli bir özellik grubuna (X) dayalı olarak bazı değerleri (Y) tahmin edecektir. Regresyon çok basit bir makine öğrenimi yaklaşımıdır ve minimum hatayla doğru

sonuçları tahmin eder. Basit doğrusal regresyon (Myers vd., 2012) için matematiksel formülasyon şu şekildedir:

$$y = f(x) + \varepsilon$$

Y bağımlı değişken (çıktı), x bağımsız değişkeni (girdi), f, x ile Y arasındaki ilişkiyi sağlayan bir fonksiyon ve ε olası rasgele hatayı temsil eder. Basit bir doğrusal regresyonun çalışma modeli Şekil 19'da gösterilmektedir. Regresyon, Kablosuz sensör ağlarında yerleştirme (Zhao vd., 2018), bağlantı sorunu (Sun vd., 2018), veri toplama (Song vd., 2013; Atoui vd., 2016; Gispan vd., 2017) ve enerji hasadı gibi çeşitli sorunları çözmek için uygulanır(Sharma vd., 2018; Tan vd., 2017). Şekil 1.18'de makine öğrenmesinde doğrusal regresyon modeli gösterilmiştir.



Şekil 1. 9. Makine Öğrenmesinde Doğrusal Regresyon Modeli

Kaynak: Fox, 2018; Kumar vd., 2019

Basit regresyon analizinin birçok uygulama alanı olmasına rağmen, gerçek hayatta karşılaşılan problemlerin birden fazla faktörü içeren bir yapıda olmasından dolayı avantajlı olmamaktadır. Bu nedenle literatürde birden fazla bağımsız değişkenin bağımlı değişkene olan etkilerinin ölçüldüğü çoklu doğrusal regresyon analizi geliştirilmiştir. Çoklu regresyon analizinin, basit regresyon analizinden farkı ise modele birden fazla bağımsız değişkenin eklenebilmesidir. Geliştirilen çoklu

regresyon analizinin uygulanmasında bir takım varsayımlar bulunmaktadır (Kalaycı, 2009):

- Veriler normal dağılıma uygun olmalıdır.
- Değişkenler doğrusal olmalıdır (üs derecesi bir olmalıdır).
- Modeldeki hata terimleri ortalaması sıfır olmalıdır.
- Geliştirilen modelde otokorelasyon sorunu olmamalıdır.
- Değişkenler arasında çoklu bağlantı problemi olmamalıdır.


1.3.3.1.2. Sınıflandırma Algoritmaları

Sınıflandırma algoritmaları en yaygın kullanılan makine öğrenmesi algoritmalarıdır. Bu nedenle makine öğrenmesi, ilk ortaya çıktığı dönemlerde yapılan birçok çalışmada sınıflandırıcı sistemler olarak anılmıştır (Booker vd., 1989). Makine öğrenmesi uygulamalarında ele alınan probleme bağlı olarak sınıflandırma problemlerinde uygulanan yöntemlerde değişiklikler olabilmektedir. Bundan dolayı bu problemlerde sonuçlar tek ya da çok etiketli olabilmektedir. Tek etiketli sonuçların elde edildiği bir problemde mevcut veri etiketlerinden birisi atanırken; çok etiketli problemlerde birden fazla etiket kullanılmaktadır (Sebastiani, 2002).

Sınıflandırma problemleri ya da örüntü tanıma; mevcut verilerin etiket adı verilen sınıflandırmalarının bulunduğu veri kümelerinde, sınıflandırılmamış verilerin hâlihazırda belirlenmiş olan sınıflara atanması işleminin gerçekleştirildiği problemlerdir. Bu metot çerçevesinde yapılan analizlerde üretilen her bir çıktı bir sınıf; uygulanan algoritma ise sınıflandırıcı olarak ifade edilmektedir (Fawcett, 2006). Bir başka ifade ile geliştirilen bir sınıflama modeli, tahmini yapılacak verilerden sınıfları belli olan mevcut verilere doğru bir haritalama işlemidir (Camastra ve Vinciarelli, 2008).

Sınıflandırma modelleri, ayrık yanıtlar üreten sistemler için uygundur. Matematiksel olarak yoğun modeller, hiyerarşik modeller ve katmanlı modeller altında gruplandırılacak birkaç sınıflandırma modeli vardır. Bu modellerden bazıları destek vektör makinesi (Hearst, 1998), karar ağacı (Rokach ve Maimon, 2005),

rastgele orman (Breiman, 2001), yapay sinir ađları (Chen vd., 2019) ve derin öğrenmedir (Hinton vd. 2012). Sınıflandırmaya ait örnek Şekil 1. 19’da görölmektedir.



Şekil 1. 19. Sınıflandırma

Kaynak: Bilgin, 2018

1.3.3.1.2.1. Destek Vektör Makineleri

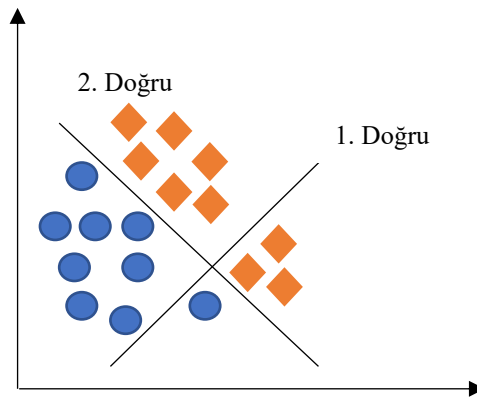
Destek vektör makineleri, Vapnik tarafından geliştirilen ve istatistiksel öğrenmeye dayanan; verileri kategorilere ayırmak için en uygun hiper düzlemi bulan denetimli bir makine öğrenimi sınıflandırıcısıdır. Destek vektör makinesi, hiperdüzlem kullanarak en iyi sınıflandırmayı gerçekleştirir ve bireysel gözlemi koordine eder (Vapnik, 1999). Eğitim verilerinin çođu, bir sınır oluşturulduğunda anlamsız olmaktadır ve bir sınıf şeklinde olmayan noktalar, sınırın belirlenmesine yardımcı olmaktadır. Eğitim verileri kullanılarak sınırı bulmak için kullanılan noktalara destek vektörleri denilmektedir. Destek vektör makinesi, belirli bir veri kümesinden en iyi sınıflandırmayı sağlamaya yaramaktadır. Bu nedenle, bir destek vektör makinesinin model karmaşıklığı, eğitim verilerinde karşılaşılan özelliklerin sayısından etkilenmeme avantajı sağlamaktadır (Kumar, 2019).

Destek vektör makinesi (Hearst, 1998), bir regresyon modeli ve bir algoritma yerine bir sınıflandırma öğrenme modeli ve bir algoritma sağlamaktadır. Destek vektör makinesi, doğrusal ve doğrusal olmayan modellere ayrılabilir (Hastie vd. 2009).

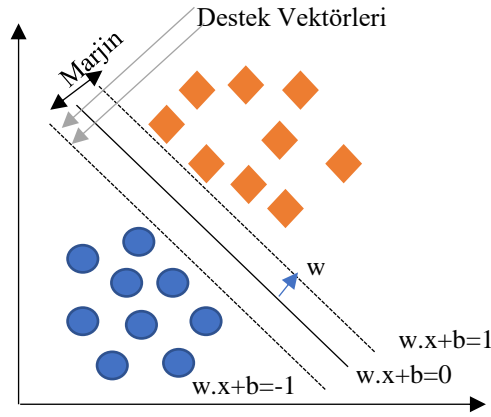
Veri alanı, orijinal alandaki sınıfları ayırmak için doğrusal olarak bölünebiliyorsa doğrusal destek vektör makinesi; doğrusal olarak bölünemiyorsa ve veri alanının sınıfları ayırmak için doğrusal olarak bölünebildiği özellik uzayı adı verilen bir uzaya dönüştürülebiliyorsa, buna doğrusal olmayan destek vektör makinesi denmektedir (Suthaharan, 2016).

Destek vektör makineleri, veriler sınıflandırıldığında oluşan sınıfları ayıran birçok doğru içerisinden marjini maksimum olan doğrunun seçilmesi prensibine göre çalışmaktadır. Bu yolla oluşan marjin doğruları her sınıfın doğruya en kısa mesafede bulunan sınıf üyelerine paralel olarak çizilmelidir. Çizilen bu doğrular hiperdüzlem olarak tanımlanmaktadır (Ben-Hur vd., 2008).

Destek vektör makinesi problemlerinde veriler birbirinden doğrusal olarak ayrılmakta ve bu yol ile ayrıştırılan sınıflar çoklu olarak incelenmektedir. Destek vektör makineleri ile oluşturulan bir sınıfları ayıran doğru ve çok sınıflı bir veri kümesine dair hiperdüzlem Şekil 1.20 ve Şekil 1.21’de verilmiştir. Destek vektör makinesinde eldeki verilerin sınıflandırılması ile oluşturulan sınıflar hiperdüzlemler ile birbirinden ayrılmaktadır. Oluşturulan bu yapı sonucunda karar marjini en yüksek olan hiperdüzlemin seçilmesi ile verilir. Şekil 1.20’de görülen doğrular arasında bulunan mesafeye marjin denir. Şekil 1.20’de marjin, destek vektörleri ve hiperdüzlem görülmektedir (Bilgin, 2018).



Şekil 1. 10. Sınıfları Ayıran Doğru



Şekil 1.11. İki Sınıflı Bir Veri Kümesinde Hiperdüzlemi Marjin ve Destek Vektörleri

Şekil 1.21’de gösterildiği üzere oluşan sınıfları ayıran hiperdüzlem $w.x+b=0$ ile ifade edilirken, bu hiperdüzlemler için oluşturulan destek vektörleri $w.x+b=\pm 1$ ile ölçülmektedir. İki yönlü oluşturulan destek vektörleri arasında bulunan mesafe olan ve minimize olması istenilen marjin ise $2/w$ ile bulunmaktadır. (Pradhan, 2012).

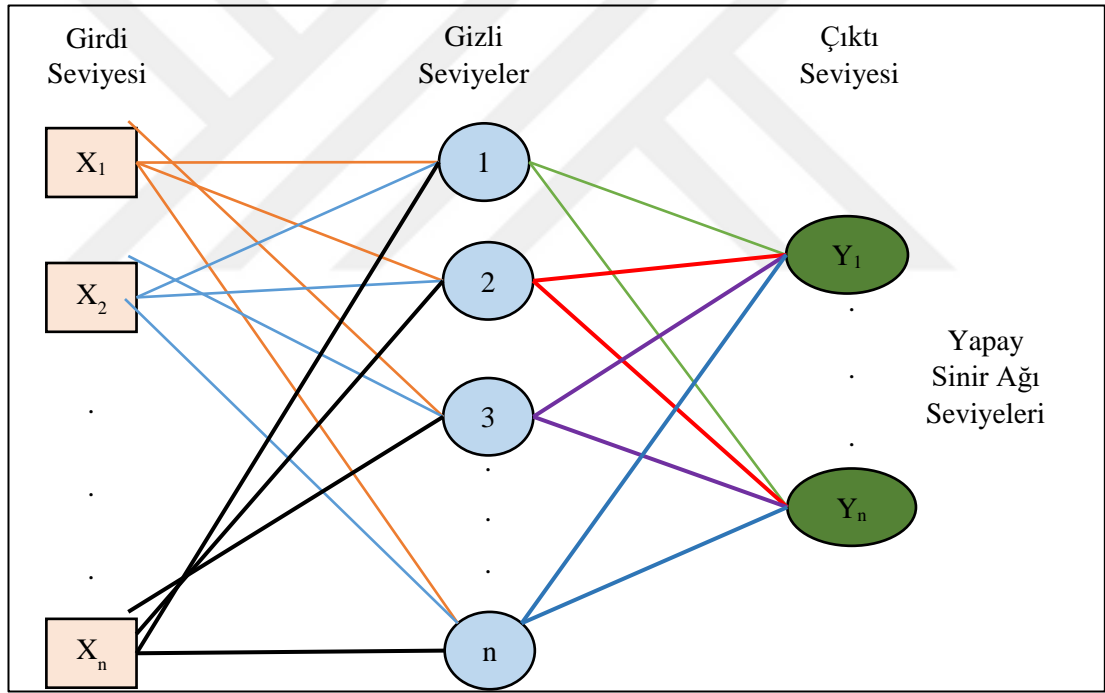
Destek vektör makinesi uygulamaları ilk olarak iki sınıflı problemler üzerine olsa da çoğunlukla odak noktasını ikiden daha fazla sınıfları olan problemler oluşturmaktadır (Biggio vd., 2012). Bu tanıma uyan problemlerin çözülmesinde sınıflandırıcılar birleştirilerek ilgili problem çözülmektedir (Lorena vd., 2009).

Destek vektör makineleri ilk olarak optik karakterlerin tanınmasından kullanılsa da (Guo vd., 2000) günümüzde el yazısının, resim ve nesnelerin, seslerin tanınması gibi alanlarda (Byun ve Lee, 2002) yaygın olarak kullanılmaktadır. Bahsedilen bu alanlar ve diğer uygulama alanlarında destek vektör makinelerinin sunduğu bir takım avantajlar bulunmaktadır (Jiang vd., 2005; Bilgin, 2018):

- Kompleks yapıdaki karar sınırlarının modellenmesini sağlar.
- Birçok bağımsız değişken geliştirilen modelde kullanılabilir.
- Doğrusal ve doğrusal olmayan verilere uygulanabilir.
- Kullanılan diğer yöntemlere göre aşırı uyum sorunu oldukça azdır.

1.3.3.1.2.2. Yapay Sinir Ağları

Bir yapay sinir ağı (YSA), verileri sınıflandırmak için bir insan nöronu modeline dayanan denetimli bir makine öğrenimi tekniğidir (White, 1989). YSA, bilgiyi işleyen ve doğru sonuçlar üreten çok sayıda nöronla (işlem birimi) bağlantılıdır. YSA tipik olarak katmanlar üzerinde çalışır, bu katmanlar düğümlerle bağlantılıdır ve her düğüm bir aktif işlevle ilişkilendirilmiştir. Şekil 22 bir YSA'nın temel katman yapısını göstermektedir. Her YSA, üç katmandan oluşmaktadır: girdi, gizli katman ya da katmanlar ile çıktı katmanı. YSA, karmaşık ve doğrusal olmayan veri kümelerini çok kolay bir şekilde sınıflandırır ve diğer sınıflandırma yöntemlerinde olduğu gibi girdiler için herhangi bir kısıtlama yoktur. Birçok gerçek zamanlı kablosuz sensör ağları uygulaması, daha yüksek hesaplama gereksinimine sahip olmasına rağmen YSA kullanmaktadır (Kumar vd., 2019).



Şekil 1.12. Makine Öğrenmesinde Bir Yapay Sinir Ağı Yapısı

Derin öğrenme, sınıflandırma için kullanılan denetimli bir makine öğrenimi yaklaşımıdır ve YSA'nın bir alt kategorisidir. Derin öğrenme yaklaşımları, çok katmanlı temsillerle (giriş katmanı ile çıkış katmanı arasında) veri öğrenme temsil yöntemleridir. En iyi çözümü elde etmek için gösterimi alt katmandan üst katmana dönüştüren basit doğrusal olmayan modüller ile oluşturulur (LeCun vd., 2015). İnsan sinir sistemlerindeki iletişim kalıplarından ve bilgi işlemeden esinlenmiştir

(Marblestone vd., 2016). Derin öğrenmenin temel faydaları, verilerden üst düzey özellikler çıkarmak, etiketli veya etiketsiz çalışmak ve birden çok hedefi yerine getirmek için eğitilebilmesidir. Biyoinformatik, sosyal ağ analizi, iş zekâsı, tıbbi görüntü işleme, konuşma tanıma, el yazısı tanıma gibi çeşitli alanlarda faydalı olabilir. Derin öğrenmenin avantajları, yapay sinir ağı araştırmacılarının ilgisini çekmiştir.

Yapay sinir ağları, insan beyninin bilgiyi işleme özelliğinden yola çıkarak, öğrenmeye dayalı yeni bilgiler üretebilme ve keşfetme gibi kabiliyetleri taklit etmek amacıyla tasarlanmış bilgisayar programlarıdır (Agatonovic-Kustrin ve Beresford, 2000). Bu özelliklerin gerçekleştirilmesi geleneksel programlama yöntemleriyle oldukça zordur (Huang ve Zhang, 1994). Yapay sinir ağları tanımlanacak olursa, insan beyni dikkate alınarak geliştirilmiş, ağırlıklı bağlantılar sayesinde birbirlerine ilişkilendirilen, paralel çalışan ve aralarında bilgi akışı olan bir bilgi işleme sistemidir (Abraham, 2005). Bu nedenle yapay sinir ağları için biyolojik sinir hücrelerinden oluşan sinir ağlarının bilgisayar ile taklit edilmesidir denilebilir (Graupe, 2019).

Adından da anlaşılacağı gibi Sinir Ağları, teknikler beynimizdeki nöronların çalışma şeklinden esinlenmiştir. Nöronların bir beyindeki düğümler biçimindeki bağlantılar aracılığıyla bağlanması gibi, teknik de benzer şekilde çalışır; düğümler (veya nöronlar), sinyalleri kenarlardan (veya bağlantılardan) oldukça karmaşık bir ağdaki diğer düğümlere iletir ve dolayısıyla bir çözüm üretir. Çeşitli sinir ağı teknikleri vardır, ancak en yaygın olanı, her bir nöronun kendisine bağlı nöronların çıktılarının ağırlıklı toplamı olarak aldığı ve girdiği ileri beslemeli hata geri yayılımıdır. Teknik, ağı girdi katmanı, gizli katmanlar ve çıktı katmanları olarak adlandırılan nöron katmanları olarak tanımlandığını varsayar. YSA'da giriş ve çıkış katmanı arasındaki gizli katman devreye girdiğinde karmaşıklık artar. Gizli katman, yine de hesaplama gücünü artırır. İleri beslemeli ağ için eğitim algoritması, Rumelhart tarafından verilen hata geri yayılımıdır (Makkar vd. 2020).

Yapay sinir ağları, insan beyninin bilgiyi işleme özelliğinden yola çıkarak, öğrenmeye dayalı yeni bilgiler üretebilme ve keşfetme gibi kabiliyetleri taklit etmek amacıyla tasarlanmış bilgisayar programlarıdır (Agatonovic-Kustrin & Beresford, 2000). Bu özelliklerin gerçekleştirilmesi geleneksel programlama yöntemleriyle oldukça zordur

(Daponte & Grimaldi, 1998). Literatürde yapay sinir ağı ile ilgili tanımlamalardan bazıları aşağıdaki gibidir: Yapay sinir ağı, insan beyni dikkate alınarak geliştirilmiş, ağırlıklı bağlantılar sayesinde birbirlerine ilişkilendirilen, paralel çalışan ve aralarında bilgi akışı olan bir bilgi işleme sistemidir (Gupta, 2013). Bu nedenle yapay sinir ağı için biyolojik sinir hücrelerinden oluşan sinir ağlarının bilgisayar ile taklit edilmesidir denilebilir (Jain vd., 1996).

Yapay sinir ağı, insan beyni dikkate alınarak öğrenme sürecinin taklit edilmesiyle elde edilen verilerden yeni veri üretebilme gibi işlevlerin matematiksel olarak modellenmesi ile gerçekleştirilen veri işleme sistemidir (Kuo, 2016). Yapay sinir ağlarının en önemli özelliği karmaşık yapıdaki ilişkilere sahip sistemlerin geçmiş bilgileri dikkate alınarak öğrenme yolu ile tahminleme, sınıflandırma, kümeleme, modelleme, optimizasyon gibi birçok probleme çözüm bulmasıdır. Yapay sinir ağı kullanıcının yeteneklerine gerek duymadan, öğrenmeyi kendi kendine gerçekleştiren sistemlerdir (Anderson, ve McNeill, 1992).

Yapay sinir ağlarının birçok çeşidi bulunmaktadır fakat bunlardan bazıları diğerlerine göre daha yaygın olarak kullanılmaktadır. İnsan beyninin fonksiyonel özelliklerine benzer şekilde; öğrenme, sınıflandırma, modelleme, tahminleme ve optimizasyon gibi konularda uygulanmaktadır (Staudenmayer vd., 2009). Yapay sinir ağının en önemli görevi, ağa gönderilen bir giriş veri setine karşılık gelecek bir çıkış veri seti belirlemektir (Bacour vd., 2006). Bunu gerçekleştirebilmek için ağ, ilgili durumun örnekleri ile eğitilerek benzer durumlar için genelleme yapabilme kabiliyetini elde eder ve böylelikle benzer durumlara karşılık gelen çıkış veri setleri belirlenir (Koch ve Salakhutdinov, 2015).

Yapay sinir ağı kullanmanın bazı avantajları aşağıdaki gibidir (Mijwel, 2018):

- Geleneksel yöntemlerde bilgiler veri tabanında saklanırken yapay sinir ağlarından ağın tamamında depolanabilir.
- Yapay sinir ağı eksik bilgiler olsa bile çıktı üretebilir. Ancak performansı eksik bilgilerin ne derecede önemli olduğuna bağlıdır.
- Yapay sinir ağlarında hücre bozulması çıktı üretilmesini engellemez. Sinir ağlarının bu özelliği ağı hatalara karşı dayanıklı hale getirir.

- Yapay sinir ağıları eğitildikten sonra genelleme yaparak ağı daha önce tanıtılmamış verileri tahmin edebilir.

Bu tarz yöntemlerin dezavantajlarından bazıları aşağıdaki gibidir (Tu, 1996; Öztemel, 2006):

- Uygun sinir ağını belirlemek için belirli bir kural yoktur genel olarak deneme yanılma yöntemi ile elde edilir. Eğer uygun ağı belirlenemezse düşük performanslı çözümler elde edilir. Sinir ağıları kabul edilebilir çözümler üretirler yani optimum sonuca ulaşamayabilir.
- Ağı eğitiminin biteceği zamanı belirlemek için herhangi bir yöntem yoktur. Hatanın belli bir değerin altına düşmesi eğitimin tamamlanmasını sağlayabilir ancak bu en iyi öğrenmenin olduğu anlamına gelmez.
- Sinir ağıının davranışlarının açıklanamaması, üretilen çözümün neden ve nasıl üretildiğine yönelik herhangi bir bilgi bulunamaması ağıın sonucuna olan güveni azaltır.

Makinelerin insan beyni gibi düşünebilmesine olanak tanıyan yapay sinir ağlarının sahip olduğu bir takım özellikler bulunmaktadır (Hinton, 1992; Singh vd., 2001; Yegnanarayana, 2009):

- Yapay sinir ağları, bilgisayarın insanlara benzer bir şekilde öğrenmesini sağlar.
- Yapay sinir ağları ağına verilen örnekler aracılığıyla öğrenirler.
- Yapay sinir ağlarının en iyi şekilde çalışabilmesi için ağıın ilk önce eğitilmesi ve performanslarının test edilmesi gerekmektedir.
- İstenilen sonuçlar elde edilmediği takdirde ağı tekrar eğitilebilir.
- Yapay sinir ağı verilen örneklere benzer olarak bilgi ve tahmin üretebilirler.
- Matematiksel modele ihtiyaç duymazlar.
- Ağı eğitildikten sonra eksik bilgi bulunması durumunda bile çalışabilir.
- Sadece nümerik bilgiler ile çalışırlar; sembolik ifadelerin sayısal değerlere dönüştürülmesi gerekmektedir.
- Kendi kendini organize etme ve öğrenebilme yetenekleri vardır.

Yapay sinir ağlarının tarihsel gelişimine bakıldığında, makinelerin insanlar gibi düşünerek işlemler yapabilmesine yönelik çalışmalar tarih boyunca hep var olmuştur. Bilimsel alanda ilk çalışmalar ise 1890 yılında James tarafından yapılan ve temel kavramların tanımlandığı (Mehrotra vd., 1997) çalışma ile başlamıştır. Takip eden süreçte birçok çalışma yapılmış olsa da ilk esas çalışma 1943 yılında Warren McCulloch ve Walter Pitts tarafından “Elektrik Beyin” isimli çalışma ile yapılarak ilk sinir ağı modeli geliştirilmiştir (McCulloch & Pitts, 1943).

McCulloch ve Pitts tarafından ilk sinir ağı modelinin tasarlanmasının ardından 1949 yılında Donald Hebb “Hebbian Öğrenme” kuralını ortaya atmıştır. 1953 yılında ise Rosenblatt tarafından tek katmanlı öğrenme modeli geliştirmiştir. 1956 yılına gelindiğinde Dartmouth Yaz Araştırma Projesi kapsamında yapay zekânın, hem yapay zekâ hem de sinir ağları için bir destek sağladığı sonucuna varılmıştır. 1958 yılında ise Rosenblatt “perceptron” yani algılayıcı nöron modelini geliştirmiştir. İlk sinir ağı modelinin geliştirilmesi, tek katmanlı öğrenme modelinin ortaya konması ve algılayıcıların oluşturulmasını takiben 1960 yılında Bernard Widrow ve Marcian Hoff ADALINE ile MADALINE modellerini geliştirerek literatüre sunmuşlardır (Widrow ve Marcian, 1960). 1960-1969 yılları arasında yaşanan bu gelişmelere bağlı olarak dönem yapay sinir ağları için altın çağ olarak ifade edilmektedir. Altın çağı takip eden ve bilgisayarların kullanılmaya başlanmasına kadar olan 1969-1986 yılları arasında ise araştırmalar teknolojik nedenler ile fazla gelişmemiş bu sebeple karanlık çağ ya da yapay zekâ kışı (Hendler, 2008) olarak adlandırılmıştır. Bilgisayar sektöründe ve bilgi teknolojisinde yaşanan hızlı gelişmeler ile beraber yapay sinir ağlarında da hızlı gelişmeler olmuştur. Tarihsel kronoloji içerisinde bu gelişmeler literatürden derlenerek özgün bir şekilde oluşturulmuş ve Tablo 1.4’te sunulmuştur:

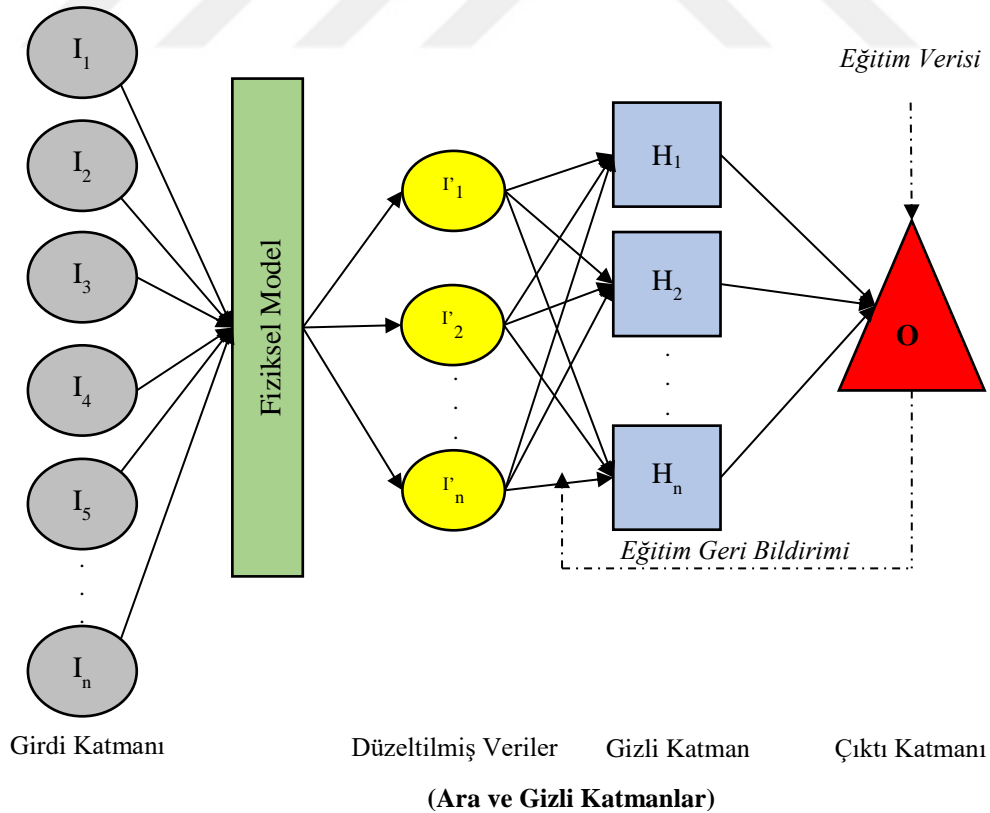
Tablo 1. 4. Yapay Sinir Ağlarının Tarihsel Gelişimi

Yıl	Gelişmeler	
	Çalışmayı Yapan	Açıklama
1943	McCulloch & Pitts	Elektrik Beyin
1949	Hebb	Sinirsel Öğrenme
1953	Rosentblatt	Tek Katmanlı Ağ Yapısı
1956	Dartmouth Yaz Araştırma Projesi	Yapay zekâ, hem yapay zekâ hem de sinir ağları için bir destek sağlar.
1957	Neumann	Neumann, telgraf röleleri veya vakum tüpleri kullanarak basit nöron işlevlerini taklit etmeyi önerdi.
1958	Rosenblatt	Algılayıcı
1960	Window & Hoff	ADALINE ve MADALINE
1969	Minsky & Papert	XOR Sorunu
1974	Werhost	Geri Yayılım
1979	Fukushima	Sinirsel Biliş
1982	Jhon Hopfield ABD-Japonya Ortak Konferansı	Hopfield Ağı İşbirlikçi/Rekabetçi Sinir Ağları
1985	Ackley Rumelhart Amerikan Fizik Enstitüsü	Boltzmann Makinesi otomatik kodlayıcı Hesaplama için Sinir Ağları Toplantısı yıllık düzenlenmeye başladı.
1986	Rumelhart, Hinton & Williams Jordan Smolensky	Çok Katmanlı Algı Tekrarlayan Sinir Ağı Yenilenen Boltzmann Machine
1995	Vapnik	Destek Vektör Makineleri
1997	Hochreiter & Schmidhuber	Uzun Kısa Süreli Bellek
1998	LeCun	Doküman Tanıma İçin Uygulanan Derece Tabanlı Öğrenme
2006	Hinton	Derin Sinir Ağı
2009	Saalakhutdinov & Hinton	Derin Boltzmann Makinesi
2012	Krizhevsky	Alex Ağı
2014	Goodfellow	Üretken Düşmanlık Ağı
2015	Ronneberger	U ağı
2016	He	Resnet
2017	Sabour	Kapsul Ağı
2018	David Ha	Üretken Sinir Ağları

Kaynak: McCarthy vd., 2006; Puttagunta ve Ravi, 2021; Kruse vd., 2022

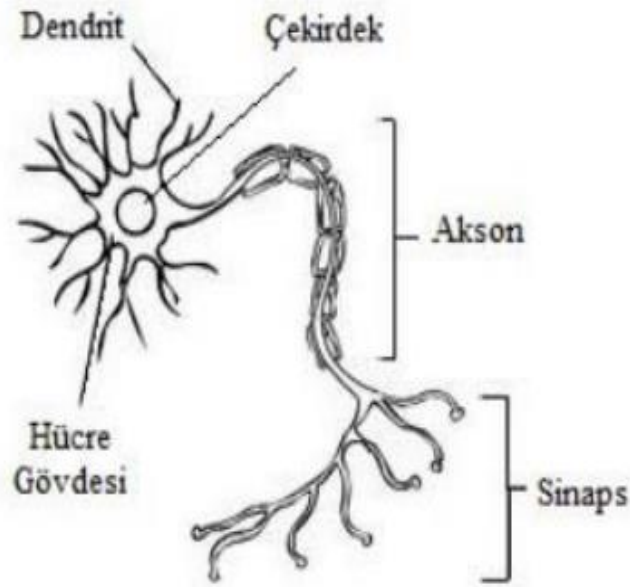
Tarihsel gelişimi Tablo 1.4’te sunulan yapay sinir ağları, yapısal olarak bir dizi düğüm ve bağlantılardan oluşmaktadır. Yapay sinir ağlarının yapı içerisinde yer alan *düğüm*ler işlemlerin gerçekleştirildiği, *bağlantılar* ise düğümler arasında bilgi akışının gerçekleştirildiği noktalardır (Wang vd., 2020). Bağlantılarda bilgi akışı tek yönlü

veya çift yönlü olarak gerçekleşebilir. Bu ağlarda, birbirleriyle bağlantılı nöronların bulunduğu giriş katmanı, ara (gizli) katman(lar) ve çıkış katmanı (Kumar vd., 2002) olmak üzere katmanlar yer almaktadır. İlk katman olan giriş katmanında girdi verileri üzerinde herhangi bir işlem uygulanmamaktadır. Giriş katmanının da veri setiyle sisteme verilen bilgilerin ağı girişi gerçekleştirilir (Lek ve Guégan, 1999). Bu veriler istatistikte bağımsız değişkenlere karşılık gelen girdi değişkenlerinden oluşur. Bu girdi verileri, giriş katmanı ve ara katman arasında bulunan nöronlara ait ağırlık değerleri ile çarpılır ve her biri ara katmana iletilir (Machado vd., 2011). Son katman olan çıkış katmanının görevi ise bilgilerin dış ortama aktarılmasını sağlamaktır. Giriş ve çıkış katmanları arasında yer alan ve sistem dışı ile bağlantısı olmayan katmanlara ise ara ya da gizli katmanlar ismi verilmektedir (Liu vd., 2023). Ağ yapısındaki diğer katmanlar ise giriş katmanı ile çıkış katmanı arasında yer alan ara (gizli) katmanlardır. Bu katmanın görevi yalnızca giriş katmanından gelen sinyalleri çıkış katmanına iletmektir (Dongare vd., 2012). Aşağıda verilen Şekil 1.23'te bahsedilen düğümler, bağlantılar ve katmanlar gösterilmiştir (Misra ve He, 2019).



Şekil 1. 13. Basit Bir Yapay Sinir Ağı Yapısı

İnsan beyninin bilgiyi kavrayarak işleme sürecine benzer bir şekilde geliştirilen yapay sinir ağları, programlama yerine insan beyni gibi uygun örnekler ile deneyimleyerek öğrenirler bu yüzden öncelikle biyolojik sinir sisteminin yapısına bir göz atmak gerekmektedir. İnsan beyni, diğer nöronlarla bağlantılı yaklaşık 100 milyar nöron içermektedir. Hücre gövdesi, dendrit, akson ve sinaps olmak üzere dört bölümden oluşan nöronlar Şekil 1.24'te gösterilmiştir. Dendritler nöronların uç kısmında yer almaktadır ve görevi komşu nöronlardan gelen bilgileri hücre gövdesine iletmektir. Hücre gövdesine gelen bilgiler aksona iletilmektedir. Bilgiler sinaps yardımıyla komşu nöronların dendritlerine iletilmektedir. Sinaps yardımıyla komşu nöronlar arasındaki bilgi akışı Şekil 1.24'te gösterilmiştir. Elektrik sinyali şeklindeki bilgi, hücre gövdesi içinde yer alan zara iletilir. Ardından sinaps boşluğunda kimyasallar salgılanır. Burada komşu nörona gelen bilgiler belirli bir eşik değerine göre yeniden oluşturulabilir. Komşu nörona iletilen bilgi miktarı, sinaptik güce ve eşik değerine bağlıdır. Bir nörona birden çok bilgi iletebilir çünkü bir nöronun yapısında çok sayıda dendrit bulunmaktadır. Bu bilgi akışı yapay sinir ağlarının gelişmesine katkı sağlamıştır (Agatonovic ve Beresford, 2000; Cain, 2016).

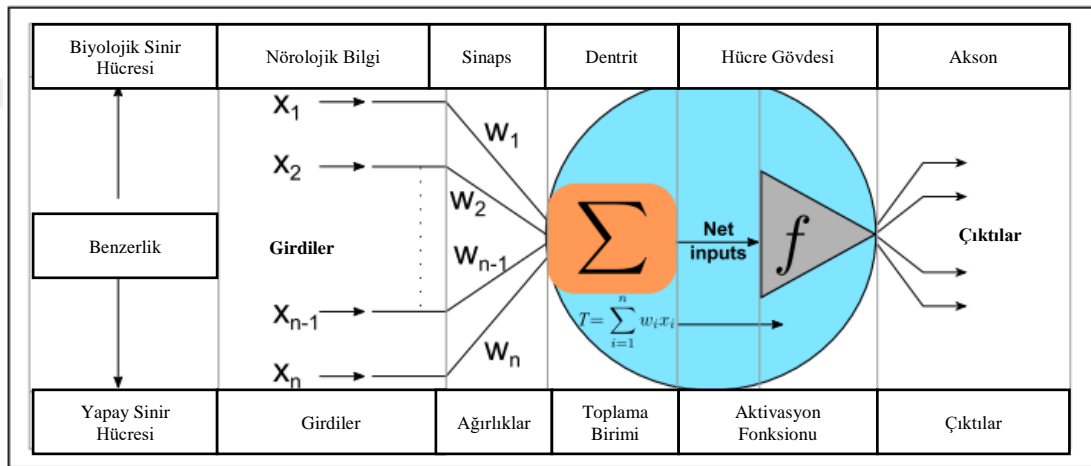


Şekil 1. 14. Basit Bir Biyolojik Sinir Hücresi Yapısı

Kaynak: https://acikders.ankara.edu.tr/pluginfile.php/192025/mod_resource/content/1/SKYYZ-Hft_10w.pdf

Yapay sinir ağı geliştirilirken insan vücudunda yer alan biyolojik sinir ağına benzetim yapılarak matematiksel olarak ifade edilmektedir. Yapay sinir hücreleri beş bileşenden oluşmaktadır (Stern, 1996):

1. Girdiler
2. Ağırlıklar
3. Toplama Fonksiyonu
4. Aktivasyon Fonksiyonu
5. Çıktı



Şekil 1.15. Yapay Sinir Ağı Mimarisi

Kaynak: Yeşilkanat vd. (2017).

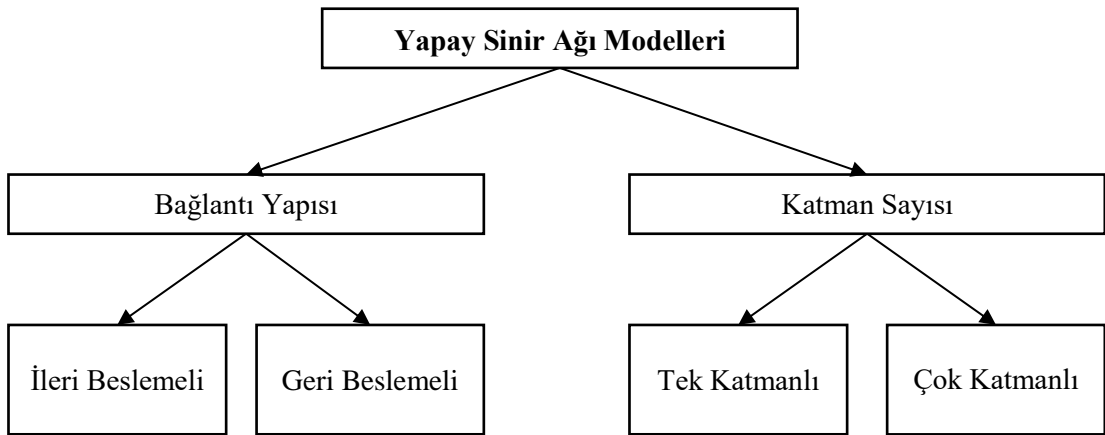
Şekil 1.25'te görüldüğü gibi ağa n tane veri girişi yapılmaktadır ve X_n girdi verilerini temsil etmektedir. Yapay sinir hücresinde, girdilerin (X_1, X_2, \dots, X_n) her biri ağırlıklar (W_n) ile toplanır ve ardından aktivasyon fonksiyonu (f) yardımıyla çıktı üretilir. Biyolojik sinir sistemi elemanları ve yapay sinir ağındaki karşılıkları ise şu şekildedir (Koç vd., 2004; Öztürk ve Şahin, 2018):

Tablo 1.5. Biyolojik Sinir Sistemi ve Yapay Sinir Ağı Eşleştirmesi

Biyolojik Sinir Sistemi	Yapay Sinir Ağı
Nöron	İşlem Elemanı
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Aktivasyon Fonksiyonu
Akson	Eleman Çıkışı
Sinaps	Ağırlıklar

- **Girdiler:** Dış ortamdan yapay sinir hücresine gelen bilgilerdir. Hücreye bilgi dış ortamdan gelebileceği gibi başka hücrelerden veya kendisinden de gelebilir (Tan ve Mayrovouniotis, 1995).
- **Ağırlıklar:** Ağırlıklar yapay sinir hücresine gelen bilginin önemini ve hücreye nasıl bir etkisi olduğunu belirler. Şekil 26’da görüldüğü gibi *ağırlık* W_n , *girdi* X_n ’nin sinir hücresi üzerindeki etkisini göstermektedir (Öztemel, 2006).
- **Toplama Fonksiyonu:** Hücreye gelen girdileri ($X_1, X_2, X_3, \dots, X_n$) ve ağırlıkları (W_1, W_2, \dots, W_n) kullanarak net girdiyi hesaplar. Ağın yapısına göre değişen çeşitli toplama fonksiyonları mevcuttur. En çok tercih edilen ağırlıklı toplama fonksiyondur (Geisler vd., 2020).
- **Aktivasyon Fonksiyonu:** Amacı hücreye gelen net girdiyi işleyerek üretilecek çıktıyı belirleyen çoğunlukla doğrusal olmayan fonksiyondur. Hücrenin çıktı değerleri genellikle $[-1, 1]$ veya $[0, 1]$ aralığında yer alır. Aktivasyon fonksiyonu içinde birçok formül mevcuttur (Elliott, 1993).
- **Çıktılar:** Aktivasyon fonksiyonu tarafından üretilen çıktı değeridir. Üretilen çıktı dış ortama, başka bir hücreye veya kendisine girdi olarak iletilebilir (Krogh, 2008).

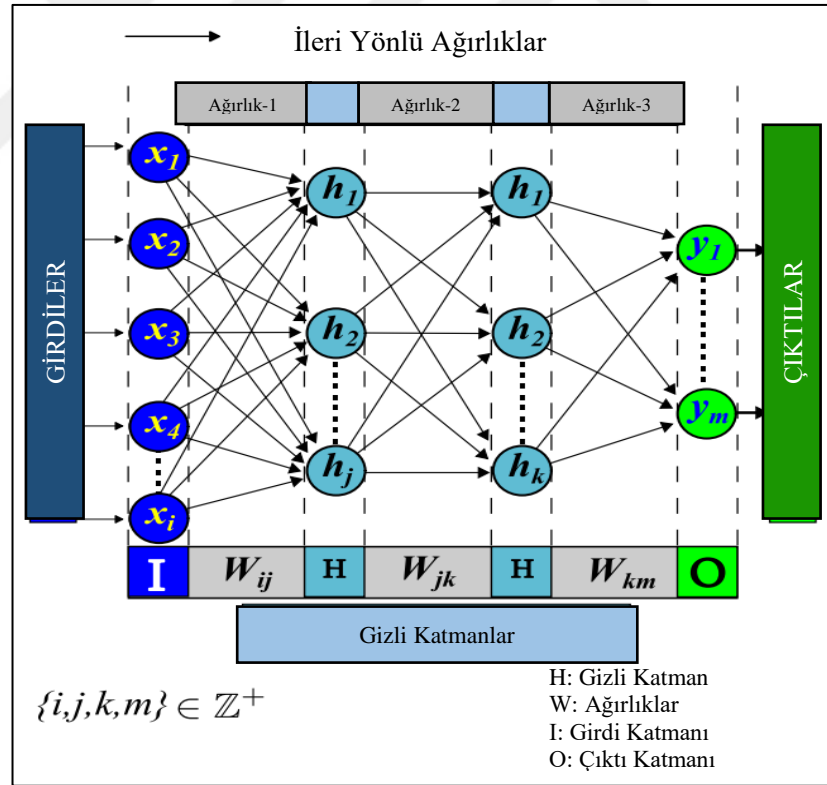
Yapay sinir ağları katmanlar arası bağlantı yapısına ve katman sayısına göre sınıflara ayrılmakta ve modellenmektedir. Şekil 1.26’ya göre bağlantı yapısı ve katman sayısına ve iki yapıya göre ise ileri ve geri beslemeli olarak sınıflandırılmaktadır.



Şekil 1. 16. Yapay Sinir Ağı Modelleri ve Sınıflandırması

Kaynak: Amin ve Murase, 2009; Abiodun vd., 2018

İleri beslemeli ağlar, birkaç katmandaki bağlantılarla bağlanan bir dizi nörondan oluşur. Temel yapılandırma genellikle bir giriş katmanı, bir gizli katman ve bir çıkış katmanı şeklindedir (Chiang vd., 2004). İleri beslemeli sinir ağlarında bir katmanın çıktısı olan veri takip eden katmanın girdisi olmaktadır (Tamura & Tateishi, 1997). Veri akışının ileri yönlü olduğu bu ağ yapısında, girdilerin ağa tanıtıldığı ve verilerin değiştirilmeden bir sonraki aşamaya iletiildiği giriş katmanından, varsa ara (gizli) katmanlara ve son olarak çıktılarının alındığı çıkış katmanına doğru tek yönlü bağlantılarla bir döngü olmadan gerçekleşmektedir (Elmas, 2003). Şekil 27’de görüldüğü gibi ara (gizli) katman W_i ağırlığına bağlı olarak girdi verisini (X_i) alır ve aktivasyon fonksiyonu kullanılarak bir çıktı üretir. Eğer ağ çok katmanlı ise bu süreç tüm gizli katmanlar için tekrarlanır. Sonuç olarak elde edilen çıktılar, başlangıçta mevcut olan çıktılarla kıyaslanarak hata değerleri tespit edilir. Şekil 1.27’te ileri beslemeli bir ağın genel yapısı gösterilmektedir (Yeşilkanat vd., 2017):




Şekil 1. 177. İleri Beslemeli Yapay Sinir Ağları

Tek katmanlı ağlar ve çok katmanlı ağlar olmak üzere iki çeşit ileri beslemeli ağ vardır. Tek katmanlı ileri beslemeli ağ yapısında bir giriş katmanı ve bir çıkış katmanı

mevcuttur. Çok katmanlı ileri beslemeli ağ yapısında ise birinci gizli katmana iletilen giriş verileri mevcuttur (Luo vd., 2016). Ağ yapısında bulunan gizli katmanların sayısının artırılması, özellikle çok sayıda ağ girişi olduğunda, ağın kabiliyetini arttırdığı yönünde etki ettiği gözlemlenmiştir (Teoh vd., 2006).

Geri beslemeli ağların ileri beslemeli ağlardan farkı bir hücrenin çıktısının yalnızca bir sonraki katmana girdi olarak verilmemesidir. Bu tür ağlarda hücre çıktısı kendisine, kendinden önceki bir katmana veya kendi katmanında yer alan bir hücreye girdi olarak verilir. Bu özelliğinden dolayı geri beslemeli ağları, doğrusal olmayan dinamik bir davranış sergilemektedir. Bu ağlarda geri besleme genellikle, gecikme olarak adlandırılan işlemci üzerinden yapılmaktadır (Turkson vd., 2016). Şekil 1.28'de geri beslemeli yapay sinir ağı sunulmuştur.



Şekil 1.188. Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli ağlarda bağlantılar bir döngü içinde olduğu için çıktının oluşumu yavaştır. Bundan dolayı ağın eğitimi daha uzun sürmektedir. Geri beslemeli ağlara Hopfield, Elman ve Jordan ağları örnek olarak söylenebilir (Szkoła vd., 2011).

1.3.3.1.2.3. K-En Yakın Komşu

K-En Yakın Komşu (K-NN), ilk olarak 1950'li yıllarda ortaya çıkan, danışmanlık öğrenme yöntemleri içerisinde en yaygın kullanılan, kayıp veriler ile çalışmayı olanaklı kılan (Pujianto vd., 2019) basit olarak regresyon ve sınıflandırmada örneğe dayalı parametrik olmayan bir öğrenme yöntemidir (Syarif ve Gata, 2017). K-NN algoritması, belirli bir veri kümesinden kolayca belirli sayıda küme oluşturmaktadır (Kanungo vd., 2002). K-NN, hem sürekli verilerde hem de ayrık verilerde esnek bir yöntemdir (Batista ve Monard, 2002). K-en yakın eğitim seti, özellik uzayından bir

girdi olarak kabul edilmektedir. K-NN genellikle belirtilen eğitim örnekleri ile test örneği arasındaki mesafeye göre sınıflandırır. K-NN algoritmasında sistemin performansı, sisteme verilen eğitim setinde yer alan örneklerin sayısına ve kapasitesinden doğrudan etkilenmektedir (Bottou ve Vapnik, 1992). K-NN algoritması Öklid uzaklığı, Hamming uzaklığı, Canberra uzaklık fonksiyonu, Manhattan uzaklığı, Minkowski uzaklığı ve Chebychev uzaklık fonksiyonu gibi çeşitli uzaklık fonksiyonlarını kullanır. K-NN algoritmasının karmaşıklığı, girdi veri kümesinin boyutuna ve verilerin aynı ölçekte olması durumunda optimum performansa bağlıdır. Bu yaklaşım özellik uzayından olası kayıp değerleri bulur ve aynı zamanda boyutsallığı azaltır (Peterson, 2009).

K-NN algoritması, sisteme dair özelliklerin ve olasılıkların bilinmediği durumlarda yani Bayes teoreminin uygulanmadığı durumlarda etkin sonuçlar vermektedir (Hattori ve Takahashi, 1999).

K-NN algoritmasında etiketlenmemiş olan gözlemler, sisteme verilen eğitim kümesi içerisinde benzer örneklerle kıyaslanmakta, o örnekler ile arasındaki mesafe Öklid mesafesine göre belirlenmektedir. Bu yol ile etiketlenmekte; bir diğer ifadeyle sınıflandırılmaktadır (Lucey ve Ashrap, 2013). Bu algorithmada bir örneğin sınıfı bulunurken benzer komşularının sayısı k olarak belirlenir. Bu katsayıya göre gözlemin hangi sınıfa ait olacağı belirlenmektedir. Bahsedilen örnek ve veri sınıfı arasındaki mesafe, konumları a ve b olarak ifade edildiğinde $|a - b|$ tanımlanmışken (Alpaydın, 2011):

$$d_1(x) \leq d_2(x) \dots \leq d_n(x)$$

formülü ile hesaplanır. Bu yol ile oluşturulan öğrenmede sınıfa olan uzaklık olarak tanımlanan x noktasına göre artan bir şekilde örnekler sıralandığında, $d_1(x)$ en yakın örneğe, $d_2(x)$ ikinci en yakın örneğe uzaklık olarak ifade edildiğinde x^t ise örnek verileri gösterdiğinde, $d_1(x) = \min_t |x - x^t|$ olarak hesaplanmaktadır.

K-NN algoritması özet olarak şu şekilde uygulanmaktadır (Jadhav ve Channe, 2016):

1. k değeri sıfırlanır.
2. Girdi örneği ile eğitim örnekleri arasındaki mesafe hesaplanır.
3. Mesafeler sıralanır.

4. En yakın komşular belirlenir.
5. Basit çoğunluk uygulanır.
6. Girdi örneği için daha fazla komşu içeren sınıf etiketini tahmin edilerek sınıf belirlenir.

K-NN algoritmasında, söz konusu k değerinin matematiksel olarak düşük olması yanlılığın azaldığını ve değişkenliğin arttığını ifade eder. Bu durumda oluşturulan model daha kompleks bir yapı haline gelmektedir. Tam tersi durumda ise yanlılık artmakta ve değişkenlik düşmektedir (Tomppo ve Halme, 2004).

K-NN algoritmasının uygulayıcılara sunduğu bir takım avantajlar bulunmaktadır (Sari, 2020):

- Uygulanması basittir.
- Gürültülü veriye karşı dirençlidir.
- Eğitim örneklerinin sayısının fazla olmasına karşı etkilidir.

K-NN algoritmasının avantajlarının yanında uygulamada karşılaşılan bir takım dezavantajları vardır (Jadhav ve Channe, 2016; Pujianto vd., 2019):

- k parametresinin belirlenmesi zor bir adımdır.
- Zaman karmaşası vardır.
- Uygulanacak uzaklık ölçüm yöntemi tanımlanmamıştır.
- Kullanılacak özellikler belirlenmemiştir.
- Uygulama maliyeti fazladır.

1.3.3.1.2.4. Rastgele Ormanlar

Rastgele orman algoritması, bir ağaç koleksiyonuyla denetimli bir makine öğrenimi tekniğidir ve ormandaki her ağaç bir sınıflandırma verir. Rastgele orman algoritması rastgele orman sınıflandırıcısının oluşturulması ve sonuçların tahmini olmak üzere iki aşamada çalışır (Breiman, 2001).

Rastgele orman, daha büyük veri kümeleri ve heterojen veriler için verimli bir şekilde çalışır. Bu yaklaşım, eksik değerleri doğru bir şekilde tahmin eder. Eğitim örneklerinin

bir alt kümesini rastgele seçmenin ve değişkenleri her ağaç düğümünde izole etmenin etkisi, çok sayıda karar ağacı üretecektir. Bu nedenle, Rastgele orman sınıflandırıcısının duyarlılık düzeyi, eğitim örneklerinin kalitesi ve aşırı sağlam karar ağaçları nedeniyle diğer düzene dayalı makine öğrenimi sınıflandırıcılarına göre daha düşüktür. Mevcut sınıflandırma metodolojileri, bir boyutluluk sorunu ve yüksek oranda ilişkili veriler nedeniyle önemli zorluklarla karşı karşıyadır. Rastgele orman sınıflandırıcı, hiperspektral verileri sınıflandırmak için en uygun yöntem olmaktadır (Belgiu ve Dragut, 2016).

Karar ağaçları koleksiyonu olarak ifade edilebilecek rastgele orman algoritmasında, bahsedilen aşırı öğrenme probleminin önüne geçilmesi amaçlanmaktadır (Al Snousy vd., 2011). Bu amaç doğrultusunda, hem veri setinden hem de özneliklerden rastgele olacak şekilde alt gruplar seçilerek çok sayıda karar ağacı oluşturulmaktadır. Oluşturulan bu karar ağaçları orman olarak ifade edilen yapıda birleştirilmektedir. Diğer bir deyişle, bahse konu karar ağaçlarının oluşturulmasında rastgele seçilen öznelikler kullanılırken, eğitilmesinde orijinal veri setinden yer değiştirme yapılarak elde edilen alt veri setleri kullanılmaktadır. Dolayısıyla, rastgele orman algoritmasında, karar ağacında olduğu gibi bütün özneliklerin arasından en iyi dalı kullanarak düğümlerin dallara ayrılması ile tek bir ağaç elde edilmesi yerine rastgele seçilen öznelikler arasından seçim yapılarak düğümlerin dallara ayrılması ile istenilen sayıda ağaç oluşturulabilmesi söz konusudur (Strobl vd., 2009).

Birbirinden farklı ağaçlardan oluşan orman içerisindeki bu ağaçlarda ise karar ağaçları algoritmalarında olduğu gibi bir budama işlemi yapılmamaktadır ki bu durum algoritmanın doğruluk oranının artmasına katkı sağlamaktadır. Budama işlemi yapılmamasının sebebi ise yukarıda belirtilen hususlardan da anlaşılacağı üzere bu algortmada farklı alt grup eğitim setleri üzerinden öğrenme gerçekleştirilmekte olduğundan zaten aşırı öğrenme probleminin azaltılmakta olmasıdır. Diğer taraftan, bu yapının olumsuz yanı ise hesaplama karmaşıklığının artmasına ek olarak karar ağaçlarında olduğu gibi oluşturulan ağaçlara ilişkin yorumlanabilecek tek bir çıktının verilememesidir (Kulkarni ve Sinha, 2012).

1.3.3.1.2.5. Naive Bayes

Naive Bayes, Bayes teoremini kullanarak bir dizi koşul verilen bir sonucun olasılığını belirleyen güçlü ve eğitilmesi kolay bir sınıflandırıcı ailesidir. Bayes teoremine göre, koşullu olasılıklar tersine çevrilir, böylece sorgu ölçülebilir büyüklüklerin bir fonksiyonu olarak ifade edilebilir. Bayes teoremine göre iki olasılıklı olay A ve B'de, marjinal olasılıklar P (A) ve P (B) ile koşullu olasılıklar P (A | B) ve P (B | A) ile çarpım kuralını kullanarak aşağıdaki gibi bir korelasyon kurulabilir (Kiraz ve Yılmaz, 2022):

$$\begin{cases} P(A \cap B) = P(A|B).P(B) \\ P(B \cap A) = P(B|A).P(A) \end{cases}$$

Kesişimin değişmeli olduğu düşünülürse, ilk üyeler eşittir; böylece Bayes teoremi şu şekilde türetilir (Bonaccorso, 2017):

$$P(A|B) = \frac{P(B|A).P(A)}{P(B)}$$

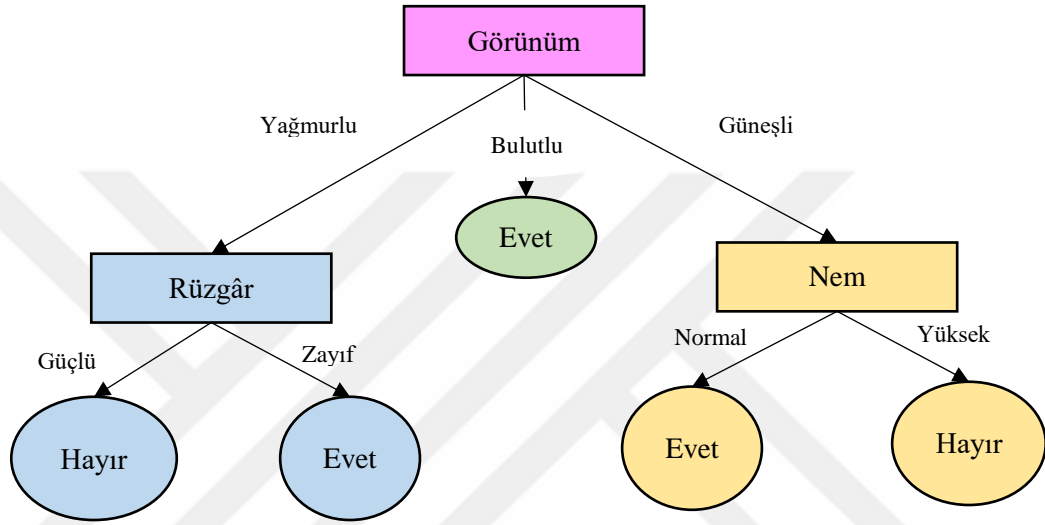
Bu formülün çok derin felsefi sonuçları vardır ve istatistiksel öğrenmenin temel bir unsurudur.

Naive Bayes algoritmasının yanı sıra tümevarım ve birliktelik kuralları ile birtakım veri madenciliği yöntemleri çalışabilmek için ayrıklaştırılmış verilere ihtiyaç duymaktadır. Bu sebepten ötürü elimizdeki bulunan verilerin içerisindeki sürekli özellikler bir takım aralık değerleri ile alt uzaylara bölünmesi gerekmektedir. Ayrıklaştırma işlemi bazen gereklilik bazen de ön işleme için önemli bir adımı ifade etmektedir. Yapılan ayrıklaştırma işlemi ile verinin yorumlanması da kolaylaşmış olmaktadır. Bu da hesaplama maliyetinin düşmesine ve hesaplama hızının artmasına yol açar. Tüm bu sayılan artılarından ötürü ayrıklaştırma işlemi çok önemli bir süreci ifade etmektedir (Grzymala-Busse ve Stefanowski, 2001).

1.3.3.1.2.6. Karar Ağaçları

Karar ağaçları (DT), uyarlanabilirliği artırmak için bir dizi *eğer öyleyse* kuralına dayalı olarak sınıflandırmaya yönelik bir denetimli makine öğrenimi yaklaşımı sınıfıdır. Karar ağaçları, sonuçları ifade eden yaprak düğümler ile alternatifler içerisinde seçim yapılmasını ifade eden karar düğümleri olmak üzere iki düğümden meydana gelmektedir (Quinlan, 1986).

Karar ağaçları algoritması, sisteme girilen eğitim ve makine öğrenimini sağlayan verilerden elde edilen ve karar vermeyi sağlayan modele göre test verisinin sınıfını bulunması ve hedefin doğru tahmin edilmesi amacıyla kullanılmaktadır. Bir karar ağacının örnek bir grafik gösterimi Şekil 1.29'da gösterilmektedir. Karar ağacının başlıca avantajları şeffaf olması, belirsizliği azaltması ve kapsamlı bir analize izin vermesidir (Olson vd., 2012)



Şekil 1. 29. Makine Öğrenmesinde Karar Ağacı Yapısı

Kaynak: Galitsky (2022)

Karar ağaçları (KA) algoritması, sıra düzensel bölümlenme (hierarchical partitioning) kategorisinde yer alan bir sınıflandırma yöntemidir (Marshall, 2001). KA, düğüm olarak tanımlanan farklı bölümleri farklı sınıflarla ilişkilendirerek verilerin hiyerarşik bir şekilde bölünmesini sağlar. Veri kümesinde her düzeyde gerçekleştirilen hiyerarşik bölümlenme işlemi, bir bölme kriteri (split criterion) kullanılarak oluşturulur. Bölme kriteri, bir veya birden çok öznelik üzerinde koşul oluşturabilir (Lee vd., 2011).

KA yönteminde genel yaklaşım, farklı düğümler üzerindeki farklı sınıflar arasındaki farklılığı en yüksek düzeye çıkarmak için eğitim verilerini özyinelemeli olarak bölmeye çalışmaktır. Bu şekilde belirli bir düğümdeki farklı sınıflar arasındaki çarpıklık (sınıflar arasında farklılık) düzeyi maksimize edildiğinde, farklı sınıflar arasındaki ayırım da maksimize edilir. Bu çarpıklığı ölçmek için Gini indeksi veya

entropi gibi farklı ölçüler kullanılmaktadır. Örneğin, herhangi bir N düğümündeki k farklı sınıfa ait bölümün $(p_1, , \dots, p_k)$, Gini indeksi $G(N)$ ise denklem şu şekilde tanımlanır (Breiman vd., 1984):

$$G(N) = 1 - \sum_{i=1}^k p_i^2$$

burada $G(N)$ 'nin değeri 0 ile $1-1/k$ arasındadır ve bu değer ne kadar küçülürse, çarpıklık da o kadar büyük olur. Gini indeksine alternatif olarak kullanılabilen bir ölçü de $E(N)$ entropi değeridir:

$$E(N) = - \sum_{i=1}^k p_i \log(p_i)$$

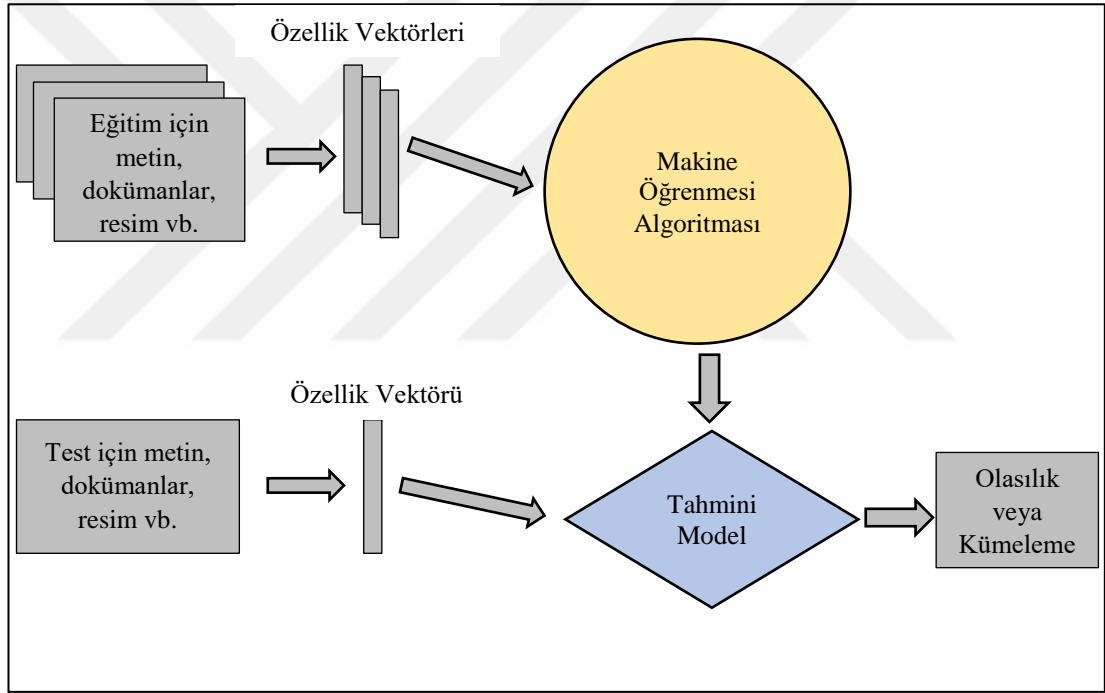
burada entropinin değeri 0 ile $\log(k)$ arasındadır. Veri kümesindeki örnekler farklı sınıflar arasında en uygun şekilde dengelendiğinde bu değer $\log(k)$ olur. Bu durum ise, maksimum entropiye sahip en uygun senaryoya karşılık gelir. Entropi ne kadar küçükse, verilerdeki çarpıklık o kadar büyük olur (Szarvas vd., 2006). Böylece, Gini indeksi ve entropi, KA'nın herhangi bir bölütleme seviyesinde yer alan bir düğümün kalitesini farklı sınıflar arasındaki ayırım düzeyi açısından değerlendirmek için etkili bir yol sağlar (Basak & Krishnapuram, 2005).

1.3.3.1.3. Danışmansız Öğrenme

Danışmansız öğrenmede, girdilerle ilişkilendirilmiş bir çıktı (etiketlenmemiş) yoktur; model bile ilişkileri verilerden çıkarmaya çalışır. Denetimsiz öğrenme yaklaşımı, benzer örüntüler kümesini kümelere ayırma, boyut azaltma ve verilerden anormallik tespiti için kullanılır (Kumar vd., 2019).

Danışmansız öğrenme, danışmanlı öğrenmede olduğu gibi sisteme herhangi bir danışman atanmasına ihtiyaç duyulmamaktadır. Makine öğrenmesinin bu türünde, çıktı katmanına dair herhangi bir bilgi elde yokken sadece girdi katmanına dair veriler sisteme girilmektedir. Sisteme yalnızca girdi verileri girildikten sonra makine öğrenmesi uygulanarak verilen örnekler ve bilgiler arasında bulunan ilişkiler bir model geliştirilerek belirlenmeye çalışılmaktadır (Nilsson, 1996).

Danışmansız öğrenme, sisteme talimat verecek insan operatör yoktur. Öğrenme algoritmasının kendisi kalıpları tanımakta ve buna göre verileri gruplandırmaktadır (Makkar vd. 2020). Danışmansız öğrenmede, çıktı katmanına dair herhangi bir bilgi mevcut olmadığı için danışmanlı öğrenmede olduğu gibi tanımlama ya da sınıflandırma gibi işlemler amaç olmamaktadır. Bu nedenle danışmansız öğrenme ile kümeleme, olasılık yoğunluk tahmini, özellikler arasındaki ilişkilerin belirlenmesi ve boyut azaltma gibi işlemler yapılabilmektedir (Chao, 2011). Bunların yanı sıra parçalayıcı ve hiyerarşik kümeleme algoritmaları da danışmansız öğrenme modeli oluşturmak üzere kullanılan algoritmalarıdır (Chakrabarti vd., 2006). Danışmansız öğrenme modeli Şekil 1.30'da gösterilmiştir.




Şekil 1. 19. Danışmansız Öğrenme

Kaynak: Bilgin (2018)

Danışmansız öğrenme algoritmaları makine öğrenmesinde genellikle kümeleme problemlerinde uygulanmaktadır. Mevcut verilere dair herhangi bir sınıfın veya etiketlemenin olmadığı durumlar altında, verilerin benzerliklerine göre gruplandırılması işlemine *kümeleme* denir. Kümeleme işlemi iki kurala göre yapılmaktadır (Bilgin, 2018):

1. Küme içi benzerliği maksimum yapması.
2. Kümeler arası benzerliğin minimum yapılması.

Elimizdeki veriler kümelere ayrıştırılırken birbirlerine olan uzaklıklarının ölçülmesi gerekmektedir. Elimizdeki verinin kesikli-süreklili ya da nominal-ordinal olmasına göre uzaklığı ölçeceğimiz metriğimizde değişiklik gösterecektir. Günümüzde kümeleme problemlerinde en sık kullanılan ölçütler: Öklid uzaklığı, Pearson uzaklığı, Spearman sıralama korelasyonu ve Manhattan uzaklığıdır. Kümeleme için örnek 1.31'de görülmektedir.



Şekil 1. 20. Kümeleme

Kaynak: Bilgin (2018)

Kümeleme problemlerinde genellikle hiyerarşik ve yumuşak kümeleme olmak üzere iki yaklaşım bulunmaktadır (Mojarad vd., 2019). *Hiyerarşik kümeleme tekniği*, benzer nesneleri yukarıdan aşağıya veya aşağıdan yukarıya önceden belirlenmiş bir düzene sahip kümeler halinde gruplandırır. Bölücü kümeleme olarak da adlandırılan yukarıdan aşağıya hiyerarşik kümeleme; bu kümelemede, büyük bir tek bölüm, her gözlem için bir kümeyle kadar yinelemeli olarak bölünür. Toplayıcı kümeleme olarak da adlandırılan aşağıdan yukarıya hiyerarşik kümeleme; bu yaklaşımda, her gözlem kendi kümesini yoğunluk fonksiyonlarına dayalı olarak atar. Hiyerarşik kümeleme yaklaşımında küme sayısı hakkında herhangi bir ön bilgiye gerek yoktur ve uygulanması kolaydır (Heller ve Ghahramani, 2005).

Hiyerarşik kümeleme algoritmalarının çalışma ilkesi eldeki veriler arasındaki uzaklıkların belirlenmesi ve bu bilgiler ışığında eldeki verilerin birleştirilmesi ya da bölünmesi şeklinde çalışan algoritmalardır. Hiyerarşik yöntemler, başlangıçta eldeki verinin her birini ayrı küme olarak kabul ederek işe başlar. Ardından da her adımda bu

kümelere birleştirilerek tek bir küme elde etmeye çalışır. Hiyerarşik yöntemlerin diğer bir türünde ise, eldeki veriler başlangıçta tek bir küme olarak ele alınarak ve her adımda alt kümelere bölünmesi şeklinde çalışan bir türü de vardır (Çoban, 2011).

Hiyerarşik yöntemlerin, dendogram adı verilen grafiksel gösterim ile daha kolay anlaşılması sağlanabilir. Dendogram, hiyerarşik kümeleme yöntemleriyle elde edilen sonuçların gösterilmesi için geliştirilmiş bir tekniktir (Bülbül vd., 2009).

Hiyerarşik kümeleme algoritmaları çalışırken benzerlik ve uzaklık ölçülerin kullanılır (Ip vd., 2010). Kullandıkları yöntemlerden dolayı farklı veri türlerinde de kolaylıkla uygulanabilir. Hiyerarşik kümeleme algoritmaları küme sayısına ihtiyaç duymadıkları için hızlıdır. Birleşme ve ayrıştırma işlemlerinin ardından kontrol işleminin uygulanmasına ihtiyaç yoktur (Dash vd., 2003).

Yumuşak kümeleme olarak da adlandırılan bulanık c-ortalama (FCM) kümeleme yöntemi ise 1981 yılında Bezdek tarafından geliştirilmiştir (Bezdek, 1981). Bu yöntemde, gözlemi bir veya daha fazla kümeye atayan bulanık küme teorisi kullanılmaktadır. Bu teknikte kümeler, yoğunluk, mesafe veya bağlanabilirlik gibi benzerlik ölçümlerine dayalı olarak tanımlanmaktadır. Uygulamalara veya veri kümelerine bağlı olarak, algoritmalar bir veya daha fazla benzerlik ölçüsü için dikkate alınmaktadır. Algoritma, en uygun küme merkezlerini bulmak için kümeler üzerinde yinelenir. FCM, örtüşen veri kümeleri için *k*-aracına kıyasla en uygun kümelemeyi üretir. *K-ortalama* kümeleme gibi, küme sayısı hakkında da ön bilgi gerekmektedir. FCM'nin zaman karmaşıklığı diğer kümeleme yaklaşımlarından daha yüksektir ve temel olarak küme sayısına, boyutlara, veri noktalarına ve iterasyonlara bağlıdır. Bu kümeleme yaklaşımı, örüntü tanıma, görüntü segmentasyonu gibi problemlerde kullanılmaktadır (Xie vd., 2016).

Danışmansız öğrenme kümeleme problemlerinin yanında değer ayrıştırma ve bileşen analizinde de yaygın olarak kullanılmaktadır (Mahesh, 2020). *Tekil değer ayrıştırma* (SVD), boyutsallığı azaltmak için kullanılan bir matris çarpanlarına ayırma yöntemidir (Bokde vd., 2015).

Bir veri seti çok deęişkenli bir yapı ile dağılım oluşturuyorsa, bu veri seti ile n adet deęişken arasındaki ilişki regresyon modelleriyle araştırılmaktadır. Bu inceleme yapılmasında yaşanan sorunlar ve deęişimlerin açıklanması için boyut indirgeme işlemi uygulanmaktadır. Boyut indirgeme işlemleri içerisinde kullanılan yöntemlerin başında temel bileşen analizi gelmektedir (Machlev vd., 2020). Bu doğrultuda temel bileşen analizi, tahmin deęişkenlerinin sayısını azaltmak ve çoklu doğrusallık problemini çözmek için yaygın olarak kullanılan geleneksel çok deęişkenli bir istatistiksel yöntemdir (Ma ve Dai, 2011).

Temel bileşen analizi, süreçte çok fazla bilgi kaybetmeden verileri özetlemek için kullanılabilir deęişkenlerin birkaç doğrusal kombinasyonunu arayan bir boyut indirgeme yöntemidir (Rosipal ve Krämer, 2006). Temel bileşen analizi, boyutluluğun azaltılması için çok deęişkenli bir analiz özellięi çıkarma yöntemidir (Ivosev vd., 2008).

Temel bileşen analizi, boyutsallığı azaltmak için tüm bilgileri birleştirmekte ve öncelik olarak daha az olan bilgileri özellik alanından çıkarmaktadır. Temel bileşen analizinin çıktısı, gözlemlenen deęişkenlerin (temel bileşenler) doğrusal bir kombinasyonudur (Suhr, 2005). Temel bileşen analizi, bazen regresyonda olduęu gibi verilerdeki anormallikleri tespit etmek için de kullanılmaktadır (Wold vd., 1987).

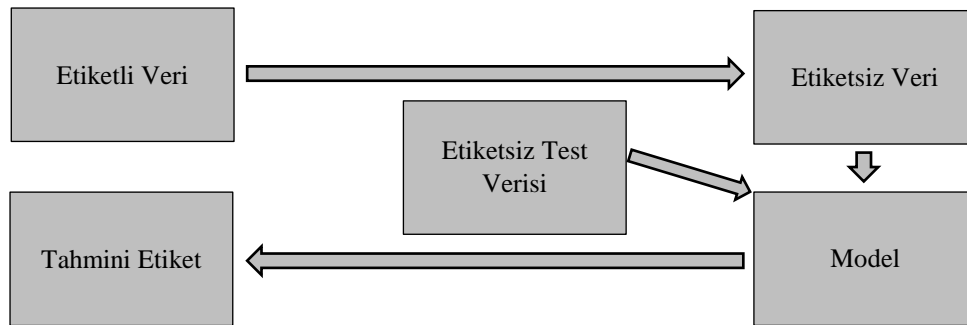
Bağımsız bileşen analizi ise, veri temsili için yeni bir temel bulur ve çok deęişkenli gözlemleri ek alt bileşenlere ayrıştırır. Buradaki alt bileşenler Gauss olmayan gözlemlerdir (Ajami ve Daneshvar, 2012). Bağımsız bileşen analizi, temel bileşen analizinden daha güçlü olan, temel bileşen analizinin genişletilmiş versiyonu olan bir tekniktir (Draper vd., 2003). Temel bileşen analizine göre bu noktada bir takım üstünlükleri vardır. Bunların en önemlisi bağımsız bileşen analizi, temel bileşen analizi ile giderilemeyen yüksek dereceli bağımlılıkları sorununu giderebilmektedir (Bartlett, 2001). Bağımsız bileşen analizi günümüzde web içerięi, dijital görüntüler, psikometrik ölçümler, iş zekâsı ve sosyal ağ gibi çeşitli uygulama alanlarından verileri analiz etmekte yaygın olarak kullanılmaktadır (Tyagi ve Chahal, 2022).

1.3.3.1.4. Yarı Danışmanlı Öğrenme

Denetimli öğrenme algoritmaları, etiketlenmiş bilgiler üzerinde verimli bir şekilde çalışırken, denetimsiz öğrenme, etiketlenmemiş veriler üzerinde verimli bir şekilde çalışır. Yarı denetimli öğrenme, hem etiketli hem de etiketsiz kombinasyonu ile veriler üzerinde çalışmaya başladı. Kısmen etiketlenmiş veriler üzerinde sınıflandırma yapmak için yarı denetimli sınıflandırmayı, hem etiketlenmiş hem de etiketlenmemiş verilerle kümeleme yapmak için kısıtlı kümelemeyi, etiketlenmemiş verilerle regresyonu ve etiketlenmiş veriler için boyutluluk azaltmayı kapsar (Zhu ve Goldberg, 2009; Hady ve Schwenker, 2013).

Eğitim setindeki etiketlenmemiş veriler üzerindeki etiketleri tahmin etmek ve gelecekteki test veri setlerindeki etiketleri tahmin etmek olan yarı denetimli öğrenmenin iki farklı hedefi vardır. Bu hedeflerle ilgili olarak, yarı denetimli öğrenme iki kategoriye ayrıldı: Yarı danışmanlı öğrenme, doğal dil işleme, web içeriğini sınıflandırma, konuşma tanıma, istenmeyen e-posta filtreleme, video gözetimi ve protein dizisi sınıflandırması gibi çeşitli gerçek zamanlı uygulamalarla uyumludur (Zhu ve Goldberg, 2009).

Yarı danışmanlı öğrenme uygulanırken, danışmansız öğrenmede olduğu gibi veriler sisteme sınıflandırılmamış olarak girilir. Ancak aradaki fark çok az miktarda verinin sınıflandırılmış yani etiketinin olmasıdır. Yani sınıflandırılmış ve sınıflandırılmamış verilerin bir arada olduğu öğrenmedir. Bu öğrenme yöntemine dair özet şema Şekil 1.32'de görülmektedir (Bilgin, 2018).



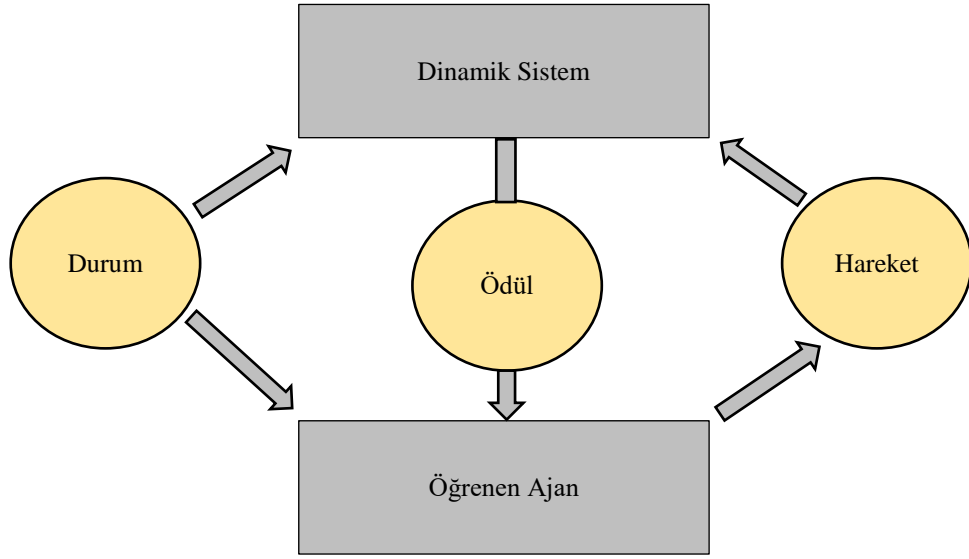
Şekil 1. 21. Yarı Danışmanlı Öğrenme

1.3.3.1.5. Takviyeli Öğrenme

Takviyeli öğrenme algoritması, çevre ile etkileşime girerek sürekli olarak öğrenmekte ve belirli eylemleri gerçekleştirmek için bilgi toplamaktadır. Bu yolla takviyeli öğrenme, ortamdan en uygun sonucu belirleyerek performansı en üst düzeye çıkarmaktadır (Watkins ve Dayan, 1992).

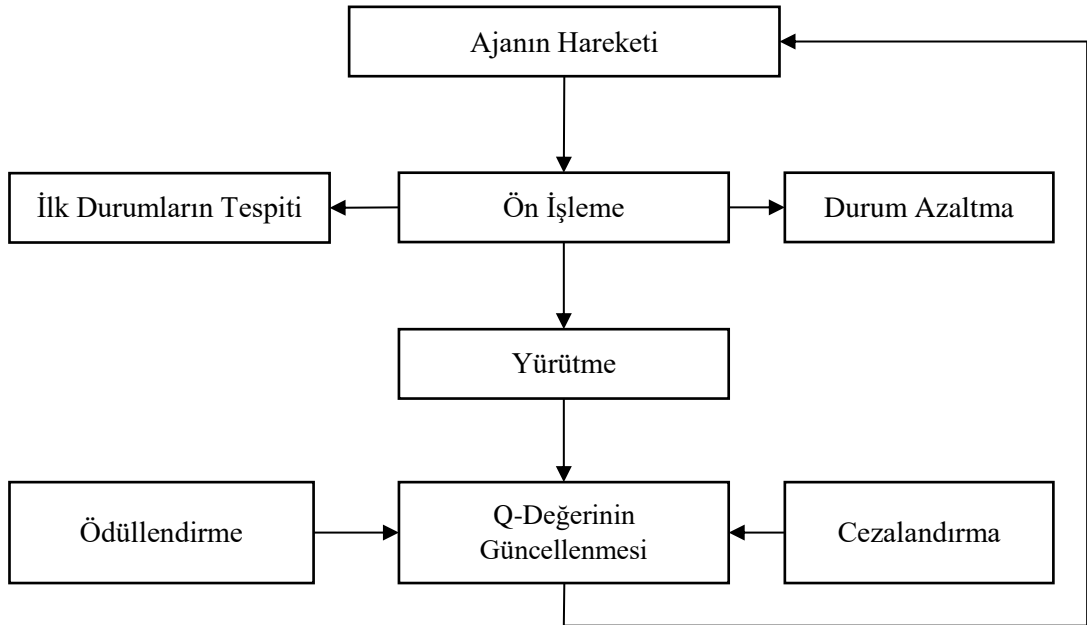
Takviyeli öğrenme modeli, danışmanlı öğrenme modeline benzemektedir. Bu yöntemde de sistemde bir danışman yer alır (Zhang vd., 2009). Takviyeli öğrenmede kullanılan danışman, eldeki mevcut veriler olan girdilerin beklenen çıktısını algoritmanın hesapladığı çıktılarla kıyaslayarak elde edilen sonucun doğruluğunu dönüt olarak iletmektedir. Bu öğrenme algoritmasında, sistemde atanan danışman karşılaşılan durumlar karşısında farklı aksiyonlar üretmektedir (Sutton ve Barto, 2018). Bu aksiyonlar neticesinde, elde edilen sonuç doğru ise sistem ödüllendirilmekte, yanlış olarak tespit edildiğinde ise cezalandırılmaktadır (Branavan vd., 2009).

Takviyeli öğrenme, düzenlenmiş olan öğrenme süreçlerinde uygulanmaktadır. Bu modelde geliştirilen algoritma, süreçte yer alan işler, parametreler ve mevcut olan çıktılara göre öğrenme gerçekleştirir (Dhaya vd., 2020). Takviyeli öğrenmede kullanılan algoritma, belirlenmiş olan kurallara göre seçenekleri ve olası ihtimalleri tahmin etmeye çalışmaktadır. Bu yolla en iyi karar verilmeye çalışılmaktadır. Eldeki verilerden en optimum sonuca ulaşılması sürecinde deneme yanılma yoluyla tüm olası ihtimaller değerlendirilir ve en iyi alternatife göre sistem uyarlanmaktadır (Makkar vd. 2014). Takviyeli öğrenme modeline dair iş akışı Şekil 1.33'te gösterilmiştir.



Şekil 1. 22. Takviyeli Öğrenme

Literatürde geliştirilmiş birçok takviyeli öğrenme algoritması mevcuttur. Hataların tespit edilmesine yönelik bir süreç iyileştirme sağlayan (Jang vd., 2019) takviyeli öğrenmenin en yaygın kullanılan algoritması, Watkins (1989) tarafından geliştirilen Q-Learning algoritmasıdır. Q-Learning algoritması bir çeşit pekiştirmeli algoritmadır. Q-Learning algoritması, rastgele bir ortam içerisinde bulunan bir faktöre, en iyi yolu göstermek amaçlanmaktadır (Watkins, 1989). Q-Learning öğrenme algoritmasının akışına dair şema Şekil 1.34'te sunulmuştur (Candan vd., 2018):



Şekil 1. 23. Q-Learning Akış Şeması

Şekil 1.35’te akış şeması görülen Q-Learning algoritmasının matematiksel denklemi en basit haliyle şu şekildedir (Kim ve Yang, 2020):

$$Q(s_{tS}, a_{tS}) \rightarrow Q(s_t, a_t) + \alpha[R(s_t, a_t) + \gamma \max Q(s_{t+1}, a_{t+1}) - Q(s_t, a_t)]$$

- $Q(s_{tS}, a_{tS})$: Yeni Q Değeri
- $Q(s_t, a_t)$: Şimdiki Q Değeri
- α : Öğrenme Oranı
- $R(s_t, a_t)$: Ödüllendirme
- γ : İndirim Faktörü
- $\max Q(s_{t+1}, a_{t+1})$: Olası Tün Eylemler

Yukarıda Bellman Denklemi verilen Q-öğrenme algoritması, belirli bir duruma dair değeri belirlemek ve bu durum karşısında alınacak kararın başarısını anlamak amacıyla kullanılmaktadır. Bu algoritma kullanıldığında elde edilen sonuç, alternatif hareketler içerisinde en optimum olanı belirlemede yardımcı olmaktadır (Singh vd., 1994).

1.4. Literatür Taraması

Makine öğrenmesi ile büyük veri analizi günümüzde oldukça yeni ve popüler olan bir çalışma alanıdır. Yapay zekânın aktif olarak var olduğu her süreçte büyük veriler elde edilmekte ve elde edilen büyük verilerin analizi de ancak yapay zekâ tabanlı yöntemlerle analiz edilmektedir. Bu bakımdan makine öğrenmesinin literatürde birçok farklı alanda uygulaması görülmektedir.

Makine öğrenimi, değer zinciri boyunca tüm kaynak kullanımının optimizasyonuna odaklandığı için günümüz perspektifindeki en iyi araçlardan biridir (Nagar vd., 2020). Girdileri tahmin etmek/algılamak için makine öğreniminde tasarlanan algoritma, tüketici merkezlidir ve makinelerin durumlarla ilgili kararlar için hızlı harekete geçmesini sağlar (Wang vd., 2016). Makine öğrenimi, durumu kesin olarak tahmin ettiğinden ve analizde geliştirilen alternatif eylemlerden mümkün olan en iyi çözümü bulmaya yardımcı olduğundan genellikle güvenilir bilgi sağlar (Dey vd., 2016). Lojistik planlamada makine öğrenimi, pazar tarafından kritik öneme sahip girdilerin (tüketici geri bildirim, pazar senaryosu, rakip analizi vb.) derinlemesine bir analizini yapmak için istatistiksel bir araç olarak hizmet eder (Wuest vd., 2016).

Carbonneau vd., (2008) tarafından yapılan çalışmada; yapay sinir ağları, tekrarlayan sinir ağları ve destek vektör makineleri dahil olmak üzere gelişmiş makine öğrenimi tekniklerinin, bir tedarik zincirinin sonunda (kamçı etkisi) çarpık talebi tahmin etmek için uygulanabilirliğini araştırmışlardır. Makine öğrenmesi yöntemlerini, Kanada Dökümhanelerine ait iki veri seti kullanarak siparişlerin tahmininde kullanarak; naive bayes, trend, hareketli ortalama ve doğrusal regresyon dahil olmak üzere diğer daha geleneksel yöntemlerle karşılaştırmışlardır.

Karakoyun ve Hacıbeyoğlu (2014) tarafından 6 tane makine öğrenmesi algoritmalarının başarımları 9 farklı biyomedikal veri kümesi üzerinde test edilerek, elde edilen sonuçlar istatistiksel olarak karşılaştırılmıştır. Deneysel ve istatistiksel sonuçlar birlikte incelediğinde küçük ve orta büyüklükteki biyomedikal veri kümeleri için Yapay Sinir Ağları algoritması sınıflandırma başarımı açısından ve Ken Yakın Komşu algoritmasının ise çalışma zamanı açısından daha başarılı olduğu tespit edilmiştir.

Kaya ve Yıldız (2014) ağ güvenliğinde etkin saldırı tespit sistemi gerçekleştirilmesine yönelik yapmış oldukları çalışmada, saldırı tespit sistemlerinde sıklıkla kullanılan makine öğrenme teknikleri araştırılmış, kullandıkları sınıflandırıcılar, veri setleri ve elde edilen başarılar değerlendirilmiştir. Bu amaçla 2007-2013 yılları arasında SCI, SCI Expanded ve EBSCO indekslerince taranan ulusal ve uluslararası dergilerde yayınlanmış 65 makale incelenmiş, sonuçlar, karşılaştırılmalı bir şekilde sunulmuştur.

Erdal ve Yapraklı (2016) tarafından yapılan çalışmada, Erzurum ilinde 38 yıldır faaliyet gösteren inşaat malzemeleri toptancısı bir firmanın müşterilerinin vadeli borçlarını ödeme/ödememe riskleri firma başarısızlığı kapsamında ele alınmış ve firma başarısızlığının tahmininde uygun bir makine öğrenmesi yöntemi araştırılmıştır. Probleme etki eden değişkenler Temel Bileşenler Analizi (TBA) ile ortaya konulmuştur. Son yıllarda makine öğrenmesinde oldukça gelişmekte olan Yapay Sinir Ağları (YSA) ve Destek Vektör Makineleri (DVM)'nin TBA yöntemiyle beraber kullanımıyla oluşturulan hibrit modellerin bu tahminde uygulanabilirliği incelenmiş ve tahmin performansları yalnız YSA ve DVM'ler ile karşılaştırılmıştır. TBA ile bütünleşik olarak kullanılan hibrit modellerin tahmin başarısının yalnız YSA ve

DVM'lere oranla daha tatmin edici sonuçlar verdiği görülmüştür. Özellikle TBA-DVM modelinin firma başarısızlığı tahminlemede alternatif bir yöntem olarak etkin bir şekilde kullanılabileceği sonucuna varılmıştır.

Kaynar vd., (2016) yapmış oldukları çalışmada, twitter da film yorumlarının içeriğine göre Naive Bayes, Merkez Tabanlı Sınıflayıcı, Çok Katmanlı Yapay Sinir Ağları (MLP) ve Destek Vektör Makineleri (SVM) gibi sınıflandırma algoritmaları kullanılarak duygu düşünce analizi yapılmıştır. Yapılan analizler sonucunda gerek eğitim gerekse test verilerinde yapay sinir ağları ve destek vektör makinalarının diğer yöntemlere oranla daha iyi sonuç verdiği gözlemlenmiştir.

Atalay ve Çelik (2017) tarafından yapılan çalışmada, büyük veri analizinde yapay zekâ ve makine öğrenmesi tekniklerinin kullanımı tartışılmıştır. Başlıca yapay zekâ ve makine öğrenmesi teknikleri hakkında bilgiler verilerek, bu tekniklerin büyük verilerle yapılan uygulamalarından örnekler verilmiştir. Yapılan çalışmada; kümeleme, sınıflandırma, yapay sinir ağları, metin ve web madenciliği, fikir madenciliği ve duygu analizi alanlarında büyük verilerle yapılan çalışmalar anlatılmıştır.

Kaynar vd., (2017) tarafından yapılan çalışmada; telekomünikasyon sektöründe müşteri kaybını tahmin etmek için, Destek Vektör Makineleri (DVM), Yapay Sinir Ağları (YSA) ve Naive Bayes (NB) gibi çeşitli sınıflama yöntemleri yardımıyla bir analiz gerçekleştirilmiştir. Analiz, açık erişimli bir veri tabanından elde edilen, 4667 müşteriden oluşan ve her müşteri için 21 adet işlem kaydına ait özellikler ile müşterinin terk edip terk etmediğine dair sınıf bilgisi içeren bir veri seti üzerinde gerçekleştirilmiştir. Analiz sonucunda, sadık ya da terk eden müşterileri sınıflamada yapay sinir ağlarının, diğer makine öğrenmesi yöntemlerine göre daha başarılı olduğu tespit edilmiştir.

Murat (2017) tarafından gerçekleştirilen araştırmada, hazırlanan 24 soruluk bir anket formu ortaöğretim 6, 7 ve 8. sınıf öğrencilerine uygulanmıştır. Anket sonuçlarından elde edilen veri üzerinde Türkçe, Matematik dersleri ve dönem sonu genel başarı ortalamalarının regresyon / çok sınıflı makine öğrenmesi modelleri oluşturularak puan

ve notları tahmin edilmiştir. Elde edilen deneysel sonuçlara göre, makine öğrenmesi yöntemleri ile öğrenci not tahmini başarılı bir şekilde gerçekleştirilmiştir.

Baryannis vd. (2019) yapmış oldukları çalışmada, yapay zeka temelli uygulamalar olan makine öğreniminin tedarik zinciri yönetimi alanında uygulamasında genellikle tahmin performansına odaklandığı ve elde edilen sonuçların riskleri azaltmada ve kararlar almada önemli olduğunu ifade etmişlerdir. Bu doğrultuda bir tedarik zincirinde risk tahminini makine öğrenmesi algoritmalarıyla yapmışlardır. Devamında tedarik zincirlerinde teslimat gecikmelerini de yine makine öğrenmesi algoritmalarıyla ele almışlar; elde edilen sonuçlarla deney sonuçları ile gerçek sonuçları karşılaştırmışlardır.

Gültepe (2019) tarafından yapılan araştırmada; Kastamonu ili ele alınarak, meteoroloji ve çevre uygulamalarında oldukça yeni ve başarılı sonuçlar veren çeşitli makine öğrenmesi algoritmaları ile hava kirliliğinin tahmininde, bazı meteorolojik parametreler kullanılarak hava kirliliği modellenmesi amaçlanmıştır. Normalizasyon tekniklerinin sistem performansına etkisini gözlemleyebilmek için veri setindeki değerler Minimum-Maksimum (Min-Max) normalizasyon teknikleri ile normalize edilmiştir. Çalışmada elde edilen performans değerleri, literatürdeki benzer çalışmalarla kıyaslanarak problemin çözümüne ilişkin en uygun sınıflandırma algoritması tespit edilmiştir. Yapay Sinir Ağları, Rastgele Orman, K-En Yakın Komşu, Lojistik Regresyon, Karar Ağacı, Lineer Regresyon ve Basit Bayes gibi yöntemler kullanılarak ayrı ayrı modeller tasarlanmış ve sonuçlar analiz edilmiştir. Veri setinin %70'i eğitim ve %30'si test verisi olarak ayrılmıştır. Çalışma sonucunda, yapay sinir ağları beklendiği gibi %91 oranında başarı göstererek en doğru tahmini yapan yöntem olarak belirlenirken, sınıflandırmalardan en başarısız sonuç Lineer Regresyon ile %30 elde edilirken, en başarılı sonuçlar Rastgele Orman ve Karar Ağacı ile %99 elde edilmiştir. KastamonuDataSet üzerinde kullanılan yöntemlerin performans değerlendirmelerinde kullanılan temel performans göstergeleri olarak Belirlilik Katsayısı, Ortalama Karesel Hata, Ortalama Hata Kare Kökü ve Ortalama Mutlak Hata metrikleri bakımından istatistiksel önemli farklılıkların bulunduğu tespit edilmiştir.

Sevli (2019) tarafından yapılan çalışmada, her biri 30 adet özellik içeren ve 569 örnekten oluşan Wisconsin Üniversitesi göğüs kanseri veri seti, beş farklı makine öğrenmesi tekniği ile sınıflandırılmıştır. Veriler rastgele olarak eğitim ve test setlerine ayrılmıştır. Destek vektör makinesi, Naïve Bayes, rastgele orman, K en yakın komşu ve lojistik regresyon metotları ile gerçekleştirilen eğitim sürecinin ardından confusion matrisleri ve roc eğrileri oluşturulmuştur. Yapılan analizler ile her bir tekniğin başarısı karşılaştırılmıştır. Çalışma sonucunda, lojistik regresyonun %98.24 doğruluk ile en başarılı yöntem olduğu ortaya konmuştur.

Qu vd., (2019) yaptıkları çalışmada bir literatür taraması yaparak, makine öğrenmesinin mikrobiyoloji alanında yer alan özellikle sınıflandırma örneklerini belirterek, alandaki uygulamalardan bahsetmişlerdir.

Wenzel vd., (2019) yaptıkları çalışmada, lojistik sektöründe makine öğrenmesi algoritmalarının kullanılmasına yönelik 2009-2019 yılları arasını kapsayan 10 yıllık bir dönemde yapılan çalışmalar üzerinde bir araştırma yaparak literatür taraması gerçekleştirmişlerdir.

Abbasi vd., (2020) tarafından yapılan çalışmada, bir hastane ağındaki kan ünitelerinin nakline karar vermek için makine öğrenimi algoritmalarını kullanarak verilecek kararları, hastanelerin ticari optimizasyon çözücülere ve hesaplama gücüne erişimi varsa elde edilen optimal sonuçlarla ve hastane ağının mevcut deneysel buluşsal politikasıyla karşılaştırmışlardır. Çalışmanın sonuçları, eğitilmiş bir yapay sinir ağı modelinin, mevcut politikaya kıyasla ortalama günlük maliyeti yaklaşık %29 oranında azaltırken, tam optimal politika ortalama günlük maliyeti %37 oranında azalttığı tespit edilmiştir.

Shahbazi ve Byun (2020) tarafından yapılan çalışmada, bozulabilir gıdaları manipüle etmek için raf ömrü yönetim sistemine dayanan; hafifliği, buharlaşmayı, depo işlemlerini ve nakliye süresini ele almak için geliştirilen blok zincir makine öğrenimi tabanlı bir gıda izlenebilirlik sistemi önerilmiştir. Blockchain veri akışı, makine öğrenmesinin, gıda izlenebilirliğini sağladığını göstermek için tasarlanmıştır.

Avşar (2021) yapmış olduğu çalışmada tedarik zinciri ile sayısal ikiz kavramlarını içeren web of science veri tabanında 58 yayına ulaşarak ayrı ayrı kümeleme analizi yapmıştır. Yapılan analizlerde bu iki kavram ile ilgili sözcükler görselleştirilerek, hangi sözcükler ile ilişkili olduklarını göstermek için söz konusu sözcükler görselleştirilmiştir.

Başer vd., (2021) gerçekleştirdikleri çalışmada; 1999-2008 yılları arasında ABD’de bulunan 130 hastanedeki 70000 kayda ait sağlık vakalarından elde edilmiş veri seti düzenlenerek, bireylerin diyabet durumuna göre sınıflandırılması hedeflenmiştir. Sınıflandırma için veri setine uygun makine öğrenmesi algoritmalarından yararlanılmış ve bu algoritmaların sonuçları performans ölçütlerine göre karşılaştırılmıştır. Elde edilen sonuçlara göre, en iyi performans gösteren beş sınıflandırma algoritması (Karar ağaçları, k-en yakın komşuluk, Lojistik regresyon, Naive Bayes ve Rastgele orman) değerlendirmeye alınmış olup en iyi doğru sınıflandırma performansı Rastgele orman algoritması ile elde edilmiştir.

Çelik ve Yelkikalan (2021) tarafından yapılan çalışmada, depo süreçlerinin iyileştirmesi hedeflenmiş ve süreçlerde oluşan firma verileri bulut teknolojileri üzerinde yer alan makine öğrenme platformlarından Azure MLStudio’da işlenmesi ele alınmıştır. Geleceğe dönük öngörü ve talep tahmin uygulamaları, makine öğrenme yöntemleri ve yapay sinir ağları gibi modellerde hesaplanmış ve kullanılan model performansları birbiriyle karşılaştırılmıştır.

Nacar ve Erdebilli (2021) tarafından gerçekleştirilen çalışmada, uçtan uca bir makine öğrenmesi proje süreci ele alınarak, herhangi bir makine öğrenmesi projesinin adımları ve veriye yaklaşım boyutu tanıtılmıştır. Uygulama bölümünde makine öğrenmesi algoritmalarından doğrusal regresyon, Ridge, Lasso, ElasticNet, K-en yakın komşu ve Rastgele Orman algoritmaları kullanılarak gerçek veri seti için bir satış tahmin modeli geliştirilmiştir. Geliştirilen modelde en düşük hatayı veren algoritma Rastgele Orman algoritması olmuştur.

Zhang vd. (2021) yapmış oldukları çalışmada tedarik zinciri bilgilerinin şirketlerin kredi notlarını tahmin etmedeki rolünü incelemiştir. Bu çalışmada firma düzeyinde

tedarikçi-müşteri bağlantılarını ve kurumsal kredi derecelendirme verilerini kullanarak, hangi tedarik zinciri özelliklerinin kredi derecelendirmelerinin tahmin doğruluğunu önemli ölçüde artırıp artıramayacağını; ne tür tedarik zinciri bağlantılarının tedarik zinciri özelliklerinin öngörülebilirliğini olumlu yönde etkileyen karar ağaçlarına sahip bir makine öğrenimi çerçevesi geliştirmişlerdir. Çalışma sonucunda, tedarik zinciri bilgileri mevcut olduğu sürece, küçük ve orta ölçekli işletmelerin ve kamu mali bilgileri olmayan özel firmaların kredi risklerini tahmin etmek için potansiyel olarak uygulanabilecek bir kredi derecelendirme tahmin modeli geliştirilmiştir.

Alazemi vd., (2022) gelişmekte olan ülkelerdeki küçük ve orta ölçekli tedarik zincirlerinde iç faktörlerin rolüne bulanık mantık çerçevesinde odaklanılarak makine öğrenmesi uygulamasının yapıldığı çalışmada, ürün tamamlanma süresi problemini ele almak için üç aşamalı bulanık tabanlı bir çerçeve önerilmiştir. Çalışma sonucunda iş akışının, malzemelerin, bakım ve onarım faaliyetleri ile insan kaynakları faktörlerinin ürün tamamlanma süresini doğrudan etkilediği tespit edilmiştir. Yapılan çalışma kapsamında önerilen Fuzzy-TOPSIS sezgisel yönteminin, ürün tamamlanma süresini% 0 ila% 10,3 arasında bir aralıkta azaltabildiğini ifade edilmiştir.

Ceyhan ve Kasapbaşı (2022) yapmış oldukları çalışmada, bir döküm fabrikasına ait 6 aylık veri toplayarak makine öğrenmesi algoritmalarından temel bileşen analizi ve rastgele orman yöntemleri ile kestirimci bir bakım uygulaması gerçekleştirmişlerdir. Yapılan analizler sonucunda bakım zamanlarını %85,17 başarı oranında tahmin etmişlerdir.

Feizabadi (2022) tarafından yapılan çalışmada ARIMAX ve Yapay sinir ağları kullanılarak hibrit bir talep tahmin modeli geliştirilmiştir. Yapılan analizler sonucunda makine öğrenmesine dayanan algoritmaların kullanılmasıyla geleneksel yöntemlere göre daha anlamlı tahminler yapıldığı belirlenmiştir.

Tuğba ve Gül (2022) yapmış oldukları çalışmada bir ilacın 36 aylık satış verilerini kullanarak ARIMA, Holt-Winters üstel düzeltme ve her iki yöntemin yapay sinir ağı yöntemlerini kullanmışlardır. Yapılan analizler sonucunda, üç yöntem sonuçlarının da

düşük hata verdiği tespit edilmiş ancak optimum sonucun kullanılan bütünleşik yapay sinir ağları ile tespit edildiği ifade edilmiştir.

Hu vd. (2023) tarafından yapılan çalışmada aşı tedarik zinciri konusu ele alınarak yaşanan üç soruna karşı karar desteği sağlaması için blok zincir, makine öğrenmesi ve nesnelerin internetini içeren bir sistem geliştirilmiştir. Yapılan analizlerde makine öğrenmesi ile aşı talebi tahmin edilmiştir.

Lei vd. (2023) yapmış oldukları çalışmada veri ön işleme, özellik seçimi, özellik sınıflandırması ve parametre ayarları olmak üzere dört aşama içeren yapay zeka tabanlı bir kurumsal risk önleme modeli geliştirmiştir. Bu aşamalarda öz nitelikleri azaltılan nicel verileri sınıflandırmak amacıyla makine öğrenmesi algoritmalarından destek vektör makinesini kullanmışlardır.

İKİNCİ BÖLÜM

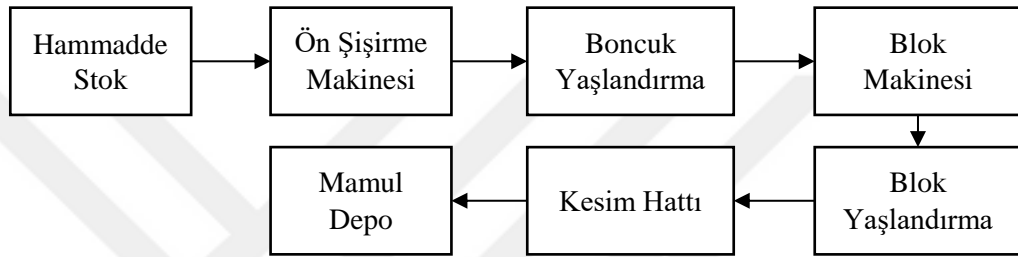
BÜYÜK VERİ VE MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE TEDARİK ZİNCİRİ YÖNETİMİ ÜZERİNE BİR UYGULAMA

Bu tez çalışması kapsamında ısı yalıtım grubu ürünler üreten bir işletmeden bir ürün grubu ait hammadde sipariş sürecine ve üretim sürecine dair veriler kullanılmıştır. Söz konusu veriler, makinelere sensörler gibi entegre bilgi teknolojileri ve IoT aracılığıyla elde edilen büyük veriler alınarak makine öğrenmesi algoritmaları ile analiz edilmiştir. Bu kapsamda çalışmanın uygulama bölümü, bir tedarik zincirinin aşamaları göz önüne alınarak hammadde tedarik süreci, üretim süreci ve dağıtım süreci olmak üzere üç kısım olarak tasarlanmıştır. İlk kısımda üretimde kullanılacak hammaddelerin temin sürecine dair veriler kullanılarak, hammadde tedarik sürecinde gecikme yaşanıp yaşanmadığı belirlenmiş ve gelecek dönemlerde farklı tedarikçilerden talep edilecek hammaddelerin teslim süreleri makine öğrenmesi algoritmalarından lineer regresyon analizi ile tahmin edilmiştir. Çalışmanın ikinci kısmında, firmanın üretim sürecine dair değişkenler kullanılarak bir ileri beslemeli çok katmanlı yapay sinir ağı modeli geliştirilerek, gerçek üretim miktarına en yakın üretim miktarını veren model belirlenmiştir. Son kısımda ise, işletmeden alınan verilerde dağıtım sürecine dair bilgi olmadığı için varsayımsal bir doğrusal programlama modeli, dağıtım maliyetlerini minimize edecek şekilde geliştirilerek LİNDÖ paket programı ile çözülmüştür.

2.1. Uygulama Yapılan Firma Hakkında Bilgi

Tez çalışması kapsamında uygulama yapılan işletme kimya sektöründe ısı yalıtım grubu ürünleri üretmektedir. Firmada farklı markalar adı altında ürünler üretilmektedir. Özellikle ısı yalıtım levhası ve kuru harç (sıva, yapıştırıcı, mineral kaplama) ürün gruplarında üretim kapasitesi olarak Avrupa'nın en büyük tesislerinden biridir.

Bu tez çalışması kapsamında, söz konusu firmanın üretim prosesi grubunda yer alan ön şişirme ve blok bölümü ele alınmıştır. Bu doğrultuda hammadde temininden, ürünlerin üretilerek satış noktalarına dağıtılmasına kadar olan tüm tedarik zinciri süreci incelenmiştir. Firmanın ön şişirme ve blok bölümünde makinelere entegre sensörler ve IoT aygıtları aracılığıyla 18 adet değişkene ait 52.866 adet veri elde edilerek analizlerde kullanılmıştır. Firmanın analizlere konu olan ön şişirme ve blok bölümünün iş akışı Şekil 2.1’de verilmiştir:



Şekil 2. 1. Ön Şişirme ve Blok Bölümü İş Akışı

Ön Şişirme ve Blok Bölümün iş akışında yer alan her bir adım ve içeriğinde yer alan faaliyetler şu şekildedir:

- **Ön Şişirme:** Hammaddeler su buharı yardımıyla belli yoğunluklarda şişirilir ve silolarda belli sürelerde bekletilir. Bekletme süresine boncuk yaşlandırma denir.
- **Blok:** bekletilen boncuklar transfer hatlarıyla blok makinesine çekilir ve yine su buharı yardımıyla blok haline getirilir.
- **Blok Yaşlandırma:** Blok haline gelen boncuklar yine belli sürelerde stok alanında bekletilir buna da blok yaşlandırma denir.
- **Kesim Hattı ve Mamul Depo:** Bekletilen bloklar en son siparişteki ölçülere göre kesim hattına alınarak istenilen kalınlıklarda kesilir ve paketlenerek sevke hazır edilir.

İşletmenin üretim alanında bulunan ön şişirme makinesinden elde edilen tarih, hammadde, çevrim sayısı, çevrimlerdeki ağırlık, ürünlerin yoğunluğu, çevrim süresi ve soğuma süresi gibi veriler önemlidir ve makinelerden sensörler ve IoT aygıtları aracılığıyla anlık olarak elde edilmektedir. Üretim sürecinde yer alan her bir döngüde

ölçülen yoğunlukların ortalaması bloğu ifade etmektedir. Blok yaşlandırma aşamasında elde edilen boncuklar, üç tonluk kapasiteye sahip olan silolarda sekiz saat dinlendirilmekte ve sonrasında kesim hattına gelerek istenilen ebat ve ağırlıkta kesilerek ürün depolarına gönderilmektedir. Bu üretim sürecinde ölçülen yoğunluk yüksek olursa fazla hammadde; düşük olursa ise hedeflenen kaliteden daha düşük ürünlerin üretildiği anlamına gelmektedir. Bu nedenle makinelerden elde edilen anlık üretim verileri takip edilmektedir. Elde edilen verilerin takip edilmesi ile hedeflenen kalite dışına sapmalar anlık olarak belirlenmekte ve sürekli kontrol gerçekleştirilmektedir. Bu durumda kalitenin sürdürülebilir kılınmasını sağlamaktadır.

2.2. Araştırmanın Amacı

Bu tez çalışmasında tedarik zinciri yönetiminde, büyük verilerin makine öğrenmesi yöntemleri ile analiz edilerek, yapay zekâya dayalı akıllı bir tedarik zinciri yönetimi örneği sunulması ve bu doğrultuda tedarik zinciri sürecinin bir bütün olarak değerlendirilmesinin yapılması amaçlanmıştır.

2.3. Araştırmanın Önemi

Tedarik zinciri yönetimi alanında bilgi teknolojilerinin kullanılarak elde edilen verileri makine öğrenmesi yöntemleri ile analiz edilmesi ve tedarik zinciri yönetiminde bir bütün olarak uygulanmasında yapılan çalışmalarda bulunan eksiklik çalışmayı önemli kılmaktadır.

2.4. Araştırmanın Kapsam ve Yöntemi

Bu tez çalışması kapsamında, kimya sektöründe faaliyet gösteren bir işletmenin bir ürün grubuna dair hammadde temini ve üretim verileri kullanılarak tüm sürecin makine öğrenmesi algoritmalarıyla ayrı ayrı analizleri yapılmıştır. Bu kapsamda gerçekleştirilen uygulamalarda, tedarik zincirinin her bir aşamasında ayrı analizler gerçekleştirilmiştir. Gerçekleştirilen analizlerde ilk olarak, firmanın ilgili aşamalarında yer alan büyük verilerden hammadde tedarik sürecine dair olanlar makine öğrenmesi yöntemlerinden lineer regresyon analizi ile işlenmiştir. Uygulanan regresyon analizi ile ileriki dönemlerde mevcut tedarikçilerden talep edilecek siparişlerin teslim edilme süreleri tahmin edilmiştir. Çalışmanın ikinci kısmında ise tasarlanan yapay sinir ağı ile gerçek üretim sürecine en yakın üretim miktarını tahmin

eden model geliştirilmiştir. Çalışmanın son kısmında ise üretilen ürünlerin dağıtılmasına dair veriler elde edilemediği için dağıtım maliyetlerini minimize edecek varsayımsal bir doğrusal programlama modeli geliştirilerek, çözülmüştür. Üç aşama olarak planlanan ve geliştirilen model ile beraber IoT tabanlı tedarik zinciri yönetimine dair bütüncül bir örnek uygulama yapılmıştır.

2.5. Uygulama


Bu tez çalışmasının uygulama bölümünde, firmanın tedarik zincirinin üç aşamasına göre sınıflandırılan ön şişirme ve blok bölümüne ait 2020-2022 yılları arası veriler kullanılmıştır. Söz konusu döneme ait hammadde teminine dair yedi değişkene ait 254 hammadde siparişi verisi ilk kısımda analiz edilmiştir. İkinci kısımda, ele alınan ürün grubunun üretimine dair toplam 52.866 veri büyük veri olarak ele alınarak yapay sinir ağı modelinde kullanılmıştır. Denetimli bir makine öğrenmesi algoritması olarak ele alınan ve geliştirilen İleri Beslemeli Çok Katmanlı Yapay Sinir Ağı modeli ile üretim miktarlarının ortalama standart hataları, ortalama hata kareleri ve belirlilik katsayıları (R^2) tespit edilmiştir. Bu yol ile gerçek üretim miktarına en yakın çıktı miktarını veren model tespit edilmiştir. Gerçekleştirilen analizlerde yer alan değişkenler ve büyük veriler içerisinde yer alan değişkenlere dair betimleyici istatistikler, söz konusu değişkenler arasındaki korelasyon ilişkisi, bir fonksiyon halinde ifade edilebilmesi ve yapay sinir ağı modeline bir temel oluşturması için çoklu regresyon analizi, söz konusu analizlerden önce uygulanarak sunulmuştur. Bu kapsamda firmadan elde edilen değişkenler ve bu değişkenlere ait veriler hammaddeye dair, sürece dair ve çıktılara dair veriler olmak üzere üç başlık altında derlenerek Tablo 2.1’de gösterilmiştir:

Tablo 2. 1. Firma Sürecine Dair Değişkenler ve Sınıflandırılması

Hammaddeye Dair Veriler	Sürece Dair Veriler	Çıktılara Dair Veriler
Sipariş Miktarı	Çevrim Zamanı	Üretim Miktarı
Teslim Süresi	Ağırlık	İstenilen Yoğunluk
Hammadde Stok Miktarı	Ölçülen Yoğunluk	Ürün Stok Miktarı
Sipariş Süresi	Buhar Sıcaklığı	
Mesafeler	Taşıma Mesafesi	
Hava Durumu	Bekleme Süresi	
	Çalışan Sayısı	
	Çalışma Süresi	
	Vardiya Durumu	
	Teorik Kapasite	

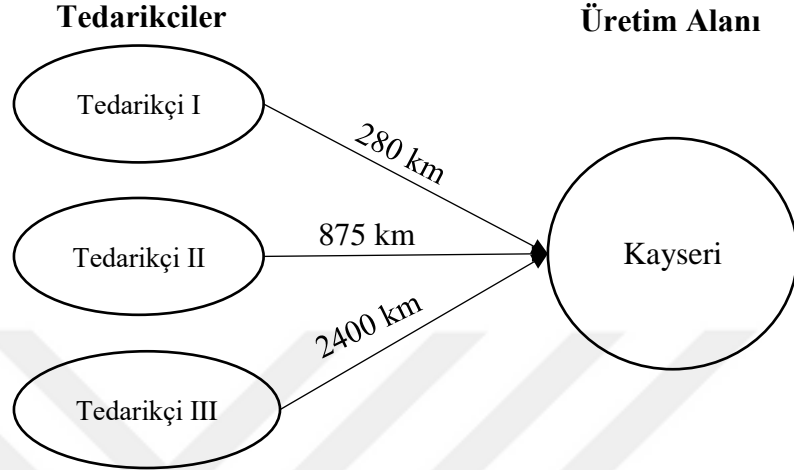
Tablo 2.1’de sunulan firmadan elde edilen deęişkenler ve bu deęişkenlere ait veriler, bir tedarik zincirinin üç ařamasında (hammadde temini, üretim süreci, üretilen ürünlerin dağıtım süreci) kullanılmıştır. Ancak bu tez çalışması bir IoT tabanlı tedarik zinciri aęı üzerine olduęu ve problemin bir üretim planlama ve çizelgeleme problemine dönüşmemesi için bazı deęişkenler tedarik zincirinde kullanılacak şekilde düzenlenmiş, çevrim ve soęuma süresi gibi bazı deęişkenler kullanılmamıştır. Bu nedenle uygulama bölümünün ilk kısmı olan hammadde tedarik sürecine dair tedarikçilerin üretim alanına mesafesi, hava durumu, talep edilen hammadde miktarı, teslim süresi, ay ve gecikme durumu deęişkenleri kullanılmıştır. Çalışmanın ikinci kısmında ise üretim sürecine dair deęişkenler ele alınmıştır. Bu doğrultuda; üretimde vardiya uygulamasının olup olmaması, çalışan sayısı, o tarihte faaliyet olup olmaması, üretimde kullanılan hammadde miktarı, istenilen ürün yoğunluğu ve hacmi, son olarak ise üretilen ürün miktarı deęişkenleri kullanılmıştır.

Bu tez çalışmasının uygulama kısmında, işletmenin ön şişirme ve blok bölümüne yönelik olarak 2020-2022 yılları arasında üç farklı tedarikçiden (Tedarikçi I, Tedarikçi II ve Tedarikçi III) toplam 254 hammadde sipariři gerçekleştirilmiştir. Söz konusu 254 sipariřin 145’i Tedarikçi I, 94’ü Tedarikçi II ve 15’i ise Tedarikçi III’te bulunan tedarikçilerden temin edilmiştir. İşletmeden edinilen bu bilgiye ek olarak söz konusu tedarikçiler ile arasındaki mesafe taşıma süresine etki ettięi için üretim alanına uzaklıkları belirlenmiş ve Şekil 37’de şematik olarak sunulmuştur. Buna ek olarak, hava şartları taşıma süresini etkiledięi için kategorik bir deęişken olarak sürece dâhil edilmiştir. Hammaddelere dair söz konusu sipariřlerin tedarikçilere göre dağılımı Şekil 2.2’de pasta grafięinde sunulmuştur.



Şekil 2. 2. Tedarikçilere Göre Sipariş Sayıları

İşletmenin söz konusu tedarikçiler ile arasındaki mesafe taşıma süresine doğrudan etki etmektedir ve bu nedenle mesafe verileri google haritalar üzerinden belirlenerek Şekil 2.3'de verilmiştir.



Şekil 2. 3. Üretim Alanı ve Tedarikçilerin Gösterimi

Tedarik zinciri aşamalarına ait değişkenlerin betimleyici istatistiklerinin belirlenmesi anlamlı sonuçlar ortaya koymaktadır. Hammadde tedarik sürecine dair değişkenlerden hava durumu ve ay kategorik değişken olarak ele alınmıştır. Bu kapsamda hava durumu 254 sipariş gününün 204'ünde iyi (1), 30'unda ise kötü (0) olarak belirlenmiştir. 28 siparişin temin sürecinde gecikme olduğu ve söz konusu gecikmelerin hava durumunun kötü olduğu günlerde gerçekleştiği tespit edilmiştir.

Firma stoka üretim yapan bir işletme olduğu için hammadde siparişlerini stoka yapmıştır. Bu kapsamda 254 hammadde siparişi, üretimin yoğunlaştığı bahar aylarında en çok verilmiştir. Söz konusu siparişlerin 60'ı Nisan ayında, 34'ü Mart ayında, 30'u ise Mayıs ayında gerçekleşmiştir. Üç bahar ayında verilen siparişlerin toplam siparişler içerisindeki oranı %49'dur. Üretim sürecinde ise vardiya uygulamasının olup olmaması kategorik bir değişken olarak kullanılmıştır ve firma üretimin yoğunlaştığı bahar aylarında toplam 48 gün vardiya uygulamasına gitmiştir.

Bu tez çalışmasının ilk kısmında ele alınan işletmenin 2020-2022 dönemine ait teslim süresi, gelen hammadde miktarı ve tedarikçiler ile mesafe değişkenlerine ait veriler kullanılmıştır. Yapılacak analizlerde mesafeye ve gelen hammadde miktarının teslim

süresine etkisinin belirlenmesi amaçlanmıştır. Bu doğrultuda panel regresyon analizi uygulanmıştır. Yapılan analizlerde Eviews 10 ve Stata 13 paket programları kullanılmıştır. Analizler uygulanmadan önce yinelenen sipariş verileri panel veri analizine uygun olmadığı için verilerin ortalaması alınarak panel veri analizine uygun hale getirilmiştir. Son olarak panel regresyon analizi uygulamasında tedarik zincirlerinde teslim süresini etkileyen bir faktör olarak hava durumu değişkeni bir kukla değişken olarak eklenmiştir. Çalışma kapsamında çalışmanın hipotezi aşağıdaki gibi tanımlanmıştır:

H_0 = Mesafe, miktar ve mevsimin teslim süresi üzerinde etkisi yoktur.

H_1 = Mesafe, miktar ve mevsimin teslim süresi üzerinde etkisi vardır.

Çalışmada ortaya konulan model aşağıdaki gibidir:

$$LNTESLIM_{it} = \beta_0 + \beta_1 LNMESSAFE_{it} + \beta_2 MEVSIM_{it} + \beta_3 LNMIKTAR_{it} + u_{it}$$

Burada β_0 sabit terimi, β_1 , β_2 , β_3 regresyon katsayıları, u hata terimidir, $i=1, 2, 3$ ve $t=1, 2, \dots, 84$.

Çalışmaya dair değişkenler Tablo 2.2’de sunulmuştur.

Tablo 2. 2. Çoklu Regresyon Analizinde Kullanılan Değişkenler

LNTESLIM	: i tedarikçinin t. dönemine ait teslim süresinin doğal logaritmasıdır.
LNMESSAFE	: i tedarikçinin t. dönemine ait km cinsinden mesafesinin doğal logaritmasıdır.
LNMIKTAR	: i tedarikçinin t. dönemine ait taşıdığı hammadde miktarının doğal logaritmasıdır.
MEVSIM	: i. tedarikçinin t. dönemine ait hava durumudur.

Çalışmaya dahil edilen tedarikçilerin 2020 – 2022 aylık dönemleri için çalışmanın değişkenleri olarak belirlenen TESLİM (Teslim Süresi), MESSAFE ve MIKTAR (Gelen Hammadde Miktarı) değişkenlerine ait betimleyici istatistikler Tablo 2.3’te sunulmuştur.

Tablo 2. 3. Değişkenlere İlişkin Betimleyici İstatistikler

Değişkenler	Ortalama	Ortanca	Standart Sapma	Minimum	Maksimum
Teslim Süresi	2,94	3,00	1,39	1	6
Mesafe	1185	875	899,07	280	2400
Gelen Hammadde Miktarı	31580,32	25368,50	9714,85	24750	61875

Tablo 2.3'e göre siparişler 1 ile 6 gün arasında, ortalama olarak ise 2,94 günde 1,39 gün standart sapmasıyla teslim alınmaktadır. Tedarikçilerin işletmeye mesafesi ise 280 ile 2400 km arasında, ortalama olarak ise 1185 km olup standart sapması 899,07 gün olarak tespit edilmiştir. İşletmeye tedarikçilerinden 24750 ile 61875 kg arasında hammadde gelmiş, ortalama gelen hammadde miktarı ise 31580 kg olarak belirlenmiş, hammadde miktarı için standart sapma değeri 9714,85 kg'dır.

İlgili dönemde işletmenin hammadde stokları incelendiğinde 71250 kg ile 600000 kg arasında değişen stok miktarlarına sahip olduğu tespit edilmiş; bu miktar ortalama olarak 285138 kg olarak ölçülmüştür. İşletmenin hammadde stok kapasitesi 600 ton olduğu ve üretimde 1125 kg ile 49500 kg arasında hammadde işlediği göz önüne alındığında bu miktarlar olumlu karşılanmaktadır. Söz konusu hammaddeler üretimde 1125 kg ile 49500 kg arasında değişen miktarlarda işlenmiş ve ortalama olarak 13714 kg hammadde işleme alınmıştır.

İşletmenin ürün stok kapasitesinin ise 800 adet (5000 m³) olduğu bilinmektedir. Bu doğrultuda işletme 13.5 kg/m³ yoğunlukta ve 6.25 m³ hacminde en fazla 800 adet ürün stoklayabilmektedir. Nitekim bu miktarın 86 ile 800 ürün arasında değişen miktarlarda olduğu tespit edilmiştir.

Panel veri analizinde modelde yer alan değişkenler arasındaki ilişkilerin belirlenmesi için korelasyon analizi uygulanmış ve sonuçlar Tablo 2.4'te sunulmuştur. Korelasyon analizi için üç ayrı hipotez kurulmuştur.

H_0 = Teslim süresi ile mesafe arasında ilişki yoktur.

H_1 = Teslim süresi ile mesafe arasında ilişki vardır.

H_0 = Teslim süresi ile gelen hammadde miktarı arasında ilişki yoktur.

H_1 = Teslim süresi ile gelen hammadde miktarı arasında ilişki vardır.

H_0 = Mesafe ile gelen hammadde miktarı arasında ilişki yoktur.

H_1 = Mesafe ile gelen hammadde miktarı arasında ilişki vardır.

Tablo 2. 4. Korelasyon Analizi Bulguları

Değişkenler	LNTESLIM	LNMESAFE	LNMIKTAR	VIF
LNTESLIM	1	0,812***	0,428***	-
LNMESAFE		1	0,269***	1,078
LNMIKTAR			1	1,078

*** 0,01 düzeyinde anlamlıdır.

Çalışmanın panel regresyon modelinde yer alan bağımlı değişken LNTESLIM ile bağımsız değişkenler LNMESAFE ve LNMIKTAR arasında sırasıyla 0,812 ve 0,428’lik pozitif ve 0,01 düzeyinde anlamlı ilişki bulunmuştur. Tablodan bağımsız değişkenler arasında ise 0,269’luk 0,01 düzeyinde anlamlı bir ilişkinin olduğu görülmektedir. Bu sonuçlara göre korelasyon analizine dayalı kurulan üç hipotez için de H_1 hipotezi kabul edilmiştir. Bağımsız değişkenler arasında çoklu bağıntı sorunu olmaması istenmektedir. Bu nedenden dolayı bağımsız değişkenler arasındaki çoklu bağıntı sorunu olup olmadığını belirlemek amacıyla varyans şişme faktörü (VIF) değerleri hesaplanmaktadır. $VIF < 10$ olması durumunda çoklu bağıntı sorunu olmadığı yorumu yapılır (Gujarati ve Porter, 2009). Çalışmada VIF değerlerine göre bağımsız değişkenler arasında çoklu bağıntı sorunu olmadığı tespit edilmiştir ($1,078 < 10$)

Panel veri analizine uygun hale getirilen veri seti ilk olarak değişkenlerin durağan olup olmamasının belirlenmesi için Dickey-Fuller birim kök testine tabi tutulmuştur. Aşağıda belirtilen hipotezlerin test edildiği birim değişkenlere ait birim kök testi sonuçları Tablo 2.5’te sunulmuştur.

H_0 : Veri durağan değildir.

H_1 : Veri durağandır.

Tablo 2. 5. Dickey-Fuller Birim Kök Testi Sonuçları

Değişkenler	İstatistik	Olasılık
LNTESLIM	-4,0074	0,0002
LNMESAFE	-8,2540	0,0000
LNMIKTAR	-8,9301	0,0000

Gerçekleştirilen Dickey-Fuller birim kök testine dair sonuçlar tabloda gösterilmiştir. Tablo 2.5’e göre çalışmada yer alan değişkenlerin tamamının durağan olduğu belirlenmiştir Tüm olasılık değerleri 0,01’den küçük değerlidir, bundan dolayı H_1 hipotezi kabul edilmiştir.

Panel regresyon analizinde, birim kök testlerinden sonra klasik, sabit etkiler ve tesadüfi etkiler modellerinden uygun olan modelin belirlenmesi amacıyla model seçimi yapılmaktadır. Moulton ve Randolph (1989) tarafından geliştirilen F testi ile bütün birimlerin etkilerinin sıfıra eşit olduğu hipotezi sınanmaktadır.

H_0 : Birim etkiler sıfıra eşittir.

H_1 : Birim etkiler sıfıra eşit değildir.

Tablo 2. 6. F Testi İstatistik Değerleri

F istatistiği	109,895
Olasılık Değeri	0,0000

Gerçekleştirilen F testi sonuçlarına göre F istatistiği değeri 109,895 ve olasılık değeri 0,000 olarak hesaplanmıştır. F istatistik değerine göre H_0 hipotezi reddedilmiştir.

Tesadüfi etkiler modeli ile sabit etkiler modelinin hangisinin seçilmesi gerektiğine dair Ki-Kare (χ^2) dağılımına uygunluğu göre karar vermeyi sağlayan Hausman testi uygulanmaktadır. Hausman testi ile hesaplanan χ^2 değerlerine göre tesadüfi etkiler modelinin geçerli olup olmadığı belirlenmekte, geçersiz olduğu durumda sabit etkiler modelinin kullanılmasına karar verilmektedir. Bu doğrultuda Hausman testi hipotezleri kurularak test sonuçları Tablo 2.7’de sunulmuştur.

H_0 : Tesadüfi Etkiler Modeli Uygundur.

H_1 : Sabit Etkiler Modeli Uygundur.

Tablo 2. 7. Hausman Test İstatistiği Sonuçları

Test Özeti	χ^2 İstatistiği	χ^2 s.d.	Olasılık
Yatay Kesit Tesadüfi	0,6973	2	0,0000

Tablo 2.7’de Hausman testi sonuçları verilmiştir. Analiz sonuçlarına göre olasılık değeri 0,0000 olarak hesaplandığı için H_0 hipotezi reddedilmiş ve sabit etkiler modeli uygulanmasına karar verilmiştir.

Panel veri analizlerinde aşağıdaki durumlardan en az birinin olması durumunda klasik, sabit etkiler veya tesadüfi etkiler modelleri geçerliliğini kaybetmekte ve bu modellerle elde edilen bulgular yanıltıcı sonuçlar vermektedir:

- Değişen varyans (heteroskedasite) olması,
- Otokorelasyon olması,
- Birimler arası ilişkinin olması.

Değişen varyans olup olmadığını tespit etmek için sabit etkiler modelinde Geliştirilmiş Wald testi uygulanmaktadır. Geliştirilmiş Wald testi için kurulan hipotezler ve Tablo 2.8’de de analiz sonuçları sunulmuştur. Geliştirilmiş Wald Testi bulgularından olasılık değerinin 0.0000 olduğu için H_0 hipotezi reddedilmektedir. Bu sonuca göre varyansın birimlere göre değiştiği tespit edilmiştir.

H_0 : Kalıntılarda değişen varyans yoktur. (Tüm i değerleri için $\sigma_i^2 = \sigma^2$)

H_1 : Kalıntılarda değişen varyans vardır. (Tüm i değerleri için $\sigma_i^2 \neq \sigma^2$)

Tablo 2. 8. Geliştirilmiş Wald Testi İstatistik Sonuçları

Ki-kare istatistiği	181,9405
Olasılık değeri	0,0000

Sabit etkiler modelinde otokorelasyon sorunun olup olmadığını belirlemek için Durbin-Watson testi uygulanmıştır. Tablo 2.9’da seriler arasında otokorelasyon olup olmadığını araştıran test istatistiği sonuçları bulunmaktadır.

H_0 : Otokorelasyon yoktur. ($\rho=0$)

H_1 : Otokorelasyon vardır. ($\rho<0$)

Tablo 2.9’den Bhargava, Franzini ve Narendranathan Durbin-Watson testi ve Baltagi-Wu yerel en iyi değişmez testiyle hesaplanan istatistik değerlerinin 4’ten küçük olduğu gözlenmektedir. Durbin-Watson sınavasında hesaplanan değerinin 0 ile 4 arasında değer aldığı aynı yönlü ardışık ilişkilerin olmadığı ifade edilmektedir (Gujarati ve

Porter, 2009). Bu nedenle, H_0 reddedilerek, sabit etkiler modeli için otokorelasyon olduğu yorumu yapılmaktadır.

Tablo 2. 9. Otokorelasyon Testi

Bhargava, Franzini ve Narendranathan'ın Durbin-Watson test istatistiği değeri	1,1539
Baltagi-Wu test istatistiği değeri	1,3533

Yatay kesit bağımlılık (birimler arası korelasyon) incelemesini gerçekleştirmek üzere aşağıdaki hipotezler kurulmuştur. Pesaran testi uygulanmıştır.

H_0 : Birimler arası korelasyon yoktur.

H_1 : Birimler arası korelasyon vardır.

Tablo 2.10'dan Pesaran testi sonucu olasılık değerinin $0,001 < 0,01$ olması nedeniyle H_0 hipotezi reddedilmiştir. Sonuç çalışma için kurulacak olan sabit etkiler modeli analizinde birimler arası korelasyon sorunu olacaktır.

Tablo 2. 10. Pesaran Test İstatistiği Sonuçları

Yatay Kesit Pesaran Bağımsızlık Testi	-8,462
Olasılık	0,001

Değişen varyans, otokorelasyon ve kesitler arası korelasyon olması durumlarına dirençli olan tahmin edicilerin kullanılması gerektiği belirlenmiştir. Çalışmada sabit etkiler regresyon modelini tahmin edebilmek için değişen varyans, otokorelasyon ve kesitler arası korelasyon olması durumlarına dirençli standart hatalar üreten Driscoll ve Kraay tahmincisi kullanılması belirlenmiştir. Sonuç olarak çalışma için kurulacak sabit etkiler modeli analizinde birimler arası korelasyon olmayacaktır.

Bu çalışma kapsamında teslim süresine etkili bir değişken olduğu için hava durumu bilgisi mevsim ismiyle bir kukla değişken olarak modele eklenmiştir. Bu doğrultuda, bağımlı değişkeni teslim süresi ve bağımsız değişkenleri mesafe, mevsim ve gelen hammadde miktarı olan çalışmada panel regresyon analizi uygulanmıştır. Panel regresyon analizi sonuçları Tablo 2.11'deki gibi belirlenmiştir.

Tablo 2.11'deki panel regresyon analizi bulgularına göre olasılık değeri incelendiğinde modelin geçerli olduğu ifade edilmektedir. Bu durumda “Mesafe ve gelen hammadde miktarının, teslim süresi üzerinde etkisi yoktur.” H_0 hipotezi reddedildiği söylenebilir. $R^2 = 0.1274$ olarak belirlenmiştir, bu değer modelde bağımsız değişkenlerin bağımlı değişkendeki değişimin %12,74'ünü açıkladığını ifade etmektedir. Regresyon katsayılarına ait t değerlerinin olasılık değerleri incelendiğinde değişkenlerin modele anlamlı katkısının olduğu belirlenmiştir.

Tablo 2. 11. Panel Regresyon Modeli Sonuçları

LNTESLİM	Driscoll/Kraay Regresyon Katsayısı	Standart Hata	t	Olasılık	[%95 Güven Aralığı]	
LNMESSAFE	0,404	0,013	30,820	0,000*	0,378	0,430
MEVSİM	-0,291	0,114	-2,560	0,010**	-0,514	-0,068
LNMIKTAR	0,292	0,075	3,880	0,000*	0,144	0,439
Sabit	-4,510	0,644	-7,00	0,000*	-5,774	-3,246

$R^2 = 0.242$
 $F(3, 72) = 5.24$
 Gözlem sayısı: n=254

*** %1, ** %5, * %10 düzeyinde anlamlı olduğunu göstermektedir.

Panel regresyon modelindeki anlamlı olduğu belirlenen regresyon katsayıları LNMESSAFE için 0,404; Mevsim için -0,291 ve LNMIKTAR için 0,292 olmuştur. Buradan, mesafe %1 arttığında teslim süresi %40 artmaktadır yorumu yapılabilir. Gelen hammadde miktarı ise %1 arttığında teslim süresi yaklaşık %29 artmaktadır yorumu yapılabilir.

Elde edilen sonuçlara göre, regresyon eşitliği şu şekilde belirlenmiştir.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3$$

$$= -4,510 + 0,404 X_1 - 0,291 X_2 + 0,292 X_3$$

Y: Teslim süresi

X_1 : Tedarikçiler ile Mesafe

X_2 : Hava Durumu

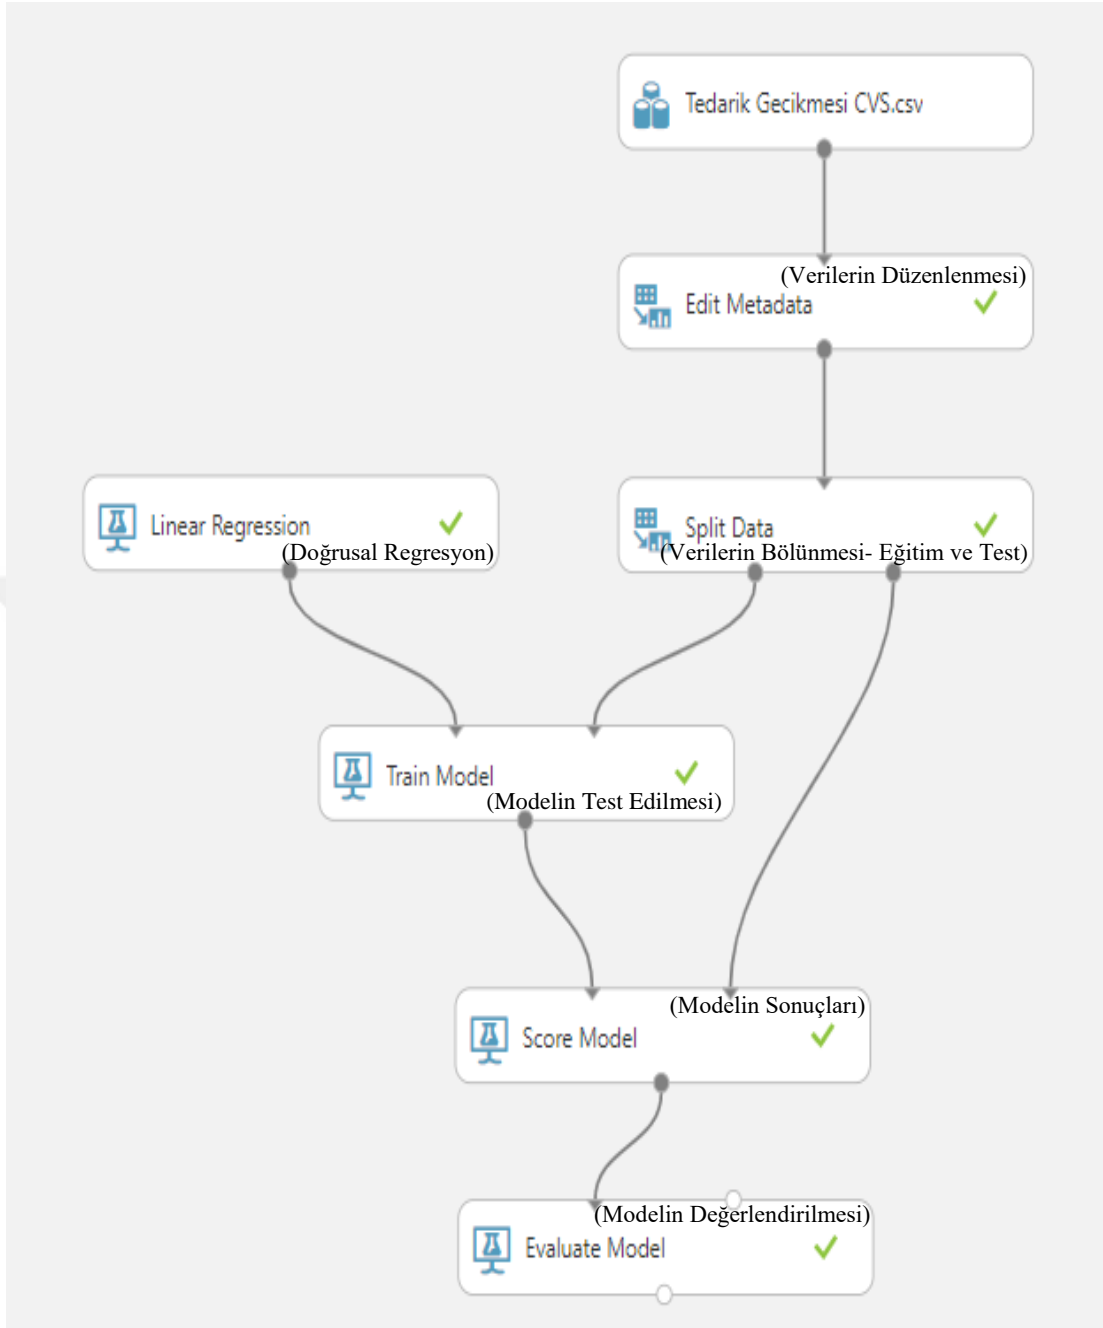
X_3 : Gelen Hammadde Miktarı

2.5.1. Makine Öğrenmesi ile Teslim Süresi Tahmini

Tedarik sürecine dair verilere uygulanan çoklu regresyon analizlerinde kullanılan bağımsız değişkenler tedarikçi, mesafe, hava durumu, ay ve gelen hammadde miktarı olarak; bağımlı değişken olarak ise teslim süresi belirlenmiştir. Kurulan bu model ile beraber işletmenin mevcut üç tedarikçisinden farklı dönem ve hava şartlarında farklı miktarlarda kaç günde hammadde sağlayacağı belirlenmiştir. Yine bu yol ile tedarikçilerin iyi ve kötü hava durumlarında (taşıma süresini etkilemektedir) kaç günde sipariş teslim edeceği belirlenmiş ve tedarik gecikmesi durumu ile karşılaşıp karşılaşılmadığı tespit edilmiştir.

İşletme 600 ton hammadde stok kapasitesine sahiptir ve stoka üretim yapıldığı için düzenli olmayan bu siparişlerde sabit sipariş miktarı 24750 kg'dır. İşletmenin tedarikçilerinden vermiş olduğu siparişlerin miktarı, ay ve yılı, hava durumu, hangi tedarikçiden sipariş verdiği, tedarikçilerin mesafeleri ve teslim süresine dair bilgilerin bir kesiti Tablo 14'te sunulmuştur.

Tedarik sürecine dair veriler kullanılarak Microsoft Azure Machine Learning Studio (AMLS) aracılığıyla tedarikçilerden temin edilen hammaddelerde bir gecikme olup olmadığı doğrusal regresyon analizi ile verilen şekildeki yapı aracılığıyla hesaplanarak *gecikme durumu* sütunu altında; kategorik bir değişken olarak eklenmiştir. Devamında işletmenin üç tedarikçiden de talep edeceği siparişleri ne kadar sürede teslim alacağı, yapay zekâ algoritması ile *tahmin* edilerek tablonun altında regresyon analizi sonuçları ile beraber sunulmuştur.



Şekil 2. 4. Tedarik Gecikmesine Dair Regresyon Modeli Akışı

Şekil 2.4’te görülen doğrusal regresyon modeli akışında tedarik sürecine dair 2020-2022 yılları arası sipariş verileri kullanılarak Tablo 2.12’de gösterilen gecikme durumu elde edilmiş ve gelecek siparişlere yönelik olarak hava durumunun iyi ve kötü olması şartları altında üç tedarikçi için temin süreleri denetimli makine öğrenmesi algoritmalarından regresyon analizi hesaplanmıştır. Hava durumu taşıma süresini etkilediği için bu değişkene ait bilgiler sipariş verilen günler için hava durumları ve yol yapım çalışması bilgileri dikkate alınarak kategorik bir değişken olarak tanımlanmıştır.

Tablo 2. 12. Tedarik Sürecine Dair Bilgiler ve Tedarik Gecikmesi

Tanım	Tedarikçi	Mesafe (km)	Hava Durumu (K/İ)	Gelen Hammadde (Kg)	Ay	Yıl	Teslim Süresi (Gün)	Gecikme Durumu (Y/V)
X Hammadde	Tedarikçi I	280	1	12375	Nisan	2021	1	0
	Tedarikçi I	280	1	1125	Nisan	2021	1	0
	Tedarikçi I	280	1	24750	Nisan	2021	2	1
	Tedarikçi II	875	1	24750	Nisan	2021	3	1
	Tedarikçi II	875	1	24750	Nisan	2021	3	1
	Tedarikçi II	875	1	24750	Nisan	2021	3	1
	Tedarikçi I	280	1	24750	Nisan	2021	3	1
	Tedarikçi I	280	1	24750	Nisan	2021	3	1
	Tedarikçi II	875	1	24750	Nisan	2021	3	1
	Tedarikçi II	875	1	24750	Nisan	2021	2	0
	Tedarikçi I	280	1	24750	Nisan	2021	1	0
	Tedarikçi I	280	1	24750	Nisan	2021	1	0
	Tedarikçi I	280	1	24750	Nisan	2021	2	0
	Tedarikçi II	875	1	24750	Nisan	2021	2	0
	Tedarikçi I	280	1	24750	Nisan	2021	2	1
	Tedarikçi II	875	1	24750	Nisan	2021	3	1
	Tedarikçi III	2400	1	24750	Nisan	2021	3	0
	Tedarikçi I	280	1	24750	Nisan	2021	1	0
	Tedarikçi II	875	1	24750	Nisan	2022	3	1
	Tedarikçi I	280	1	24750	Nisan	2022	2	1
Tedarikçi II	875	1	24750	Mayıs	2022	3	0	
Tedarikçi I	280	1	24750	Haziran	2022	1	0	

Tedarikçi I	280	1	24750	Temmuz	2022	3	1	
Tahmin	Tedarikçi I	280	1	24750	Ocak	2023	1,5	
	Tedarikçi I	280	0	24750	Ocak	2023	3,1	
	Tedarikçi II	875	1	24750	Ocak	2023	2,75	
	Tedarikçi II	875	0	24750	Ocak	2023	4,25	
	Tedarikçi III	2400	1	24750	Ocak	2023	3,84	
	Tedarikçi III	2400	0	24750	Ocak	2023	5,34	
Regresyon Analizi Sonuçları	Mean Absolute Error: 0.39							
	Root Mean Squared Error: 0.66							
	Relative Absolute Error: 0.93							
	Relative Squared Error: 0.62							
	Coefficient of Determination (R ²): 0.78							

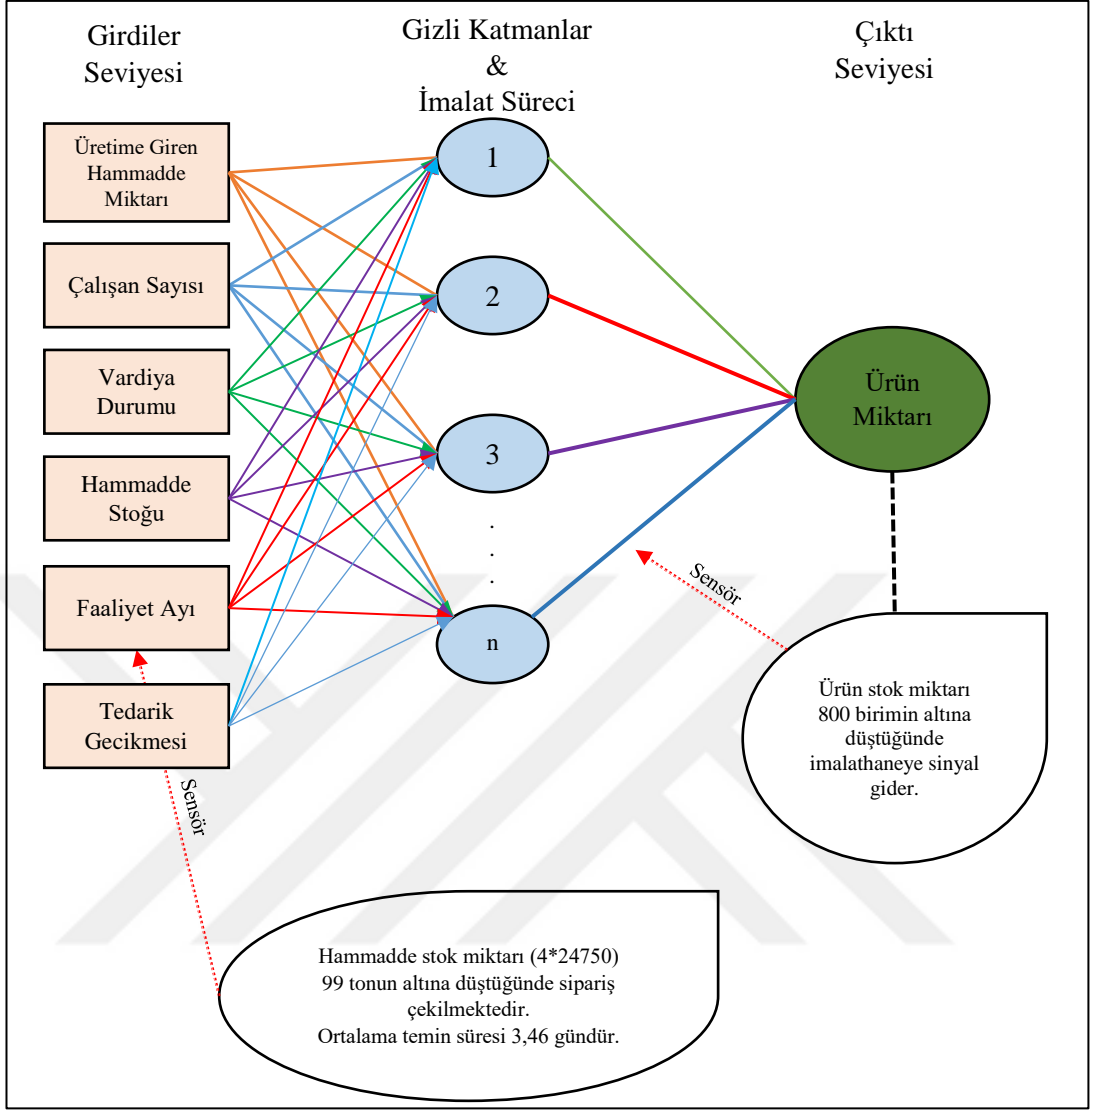
Kullanılan miktara bağılı olarak işletme stok takibi yapmakta ve ihtiyaç duyulduğunda sabit sipariş büyüklüğüne göre (24.75 ton) hammadde sipariş etmektedir. Bu siparişlerin ortalama teslim süresi $2.19 \cong 2$ gündür ve Tablo 9’da görüldüğü üzere $1.07 \cong 1$ gün standart sapmaya sahiptir. Ancak bazı aylarda mevsimsel koşullara ve tedarikçi yapısına bağılı olmak üzere 1 ile 6 gün arasında değişmektedir. Bu nedenle kullanılan miktar, sipariş miktarı ve teslim süresi değişkenlerine ay değişkeni de eklenerek model oluşturulmuştur. Bu kısımda değişkenlere ait betimleyici istatistiklerinin ve değişkenler arasındaki ilişkilerin belirlenmesinden sonra hava durumunun iyi ve kötü olması varsayımları altında gelecek dönemlere dair hammadde temin süresi tahmini yapılmıştır.

Bu tez çalışması kapsamında tedarik zincirinin ikinci aşamasını oluşturan üretim sürecine dair ileri beslemeli çok katmanlı yapay sinir ağı yapısı geliştirilerek uygulanmıştır. Bu analiz uygulanarak, gerçek üretim değerleri ile geliştirilen modelin tahmin ettiği üretim verilerinin karşılaştırması yapılacaktır.

2.5.2. Makine Öğrenmesi ile Yapay Sinir Ağı Uygulaması

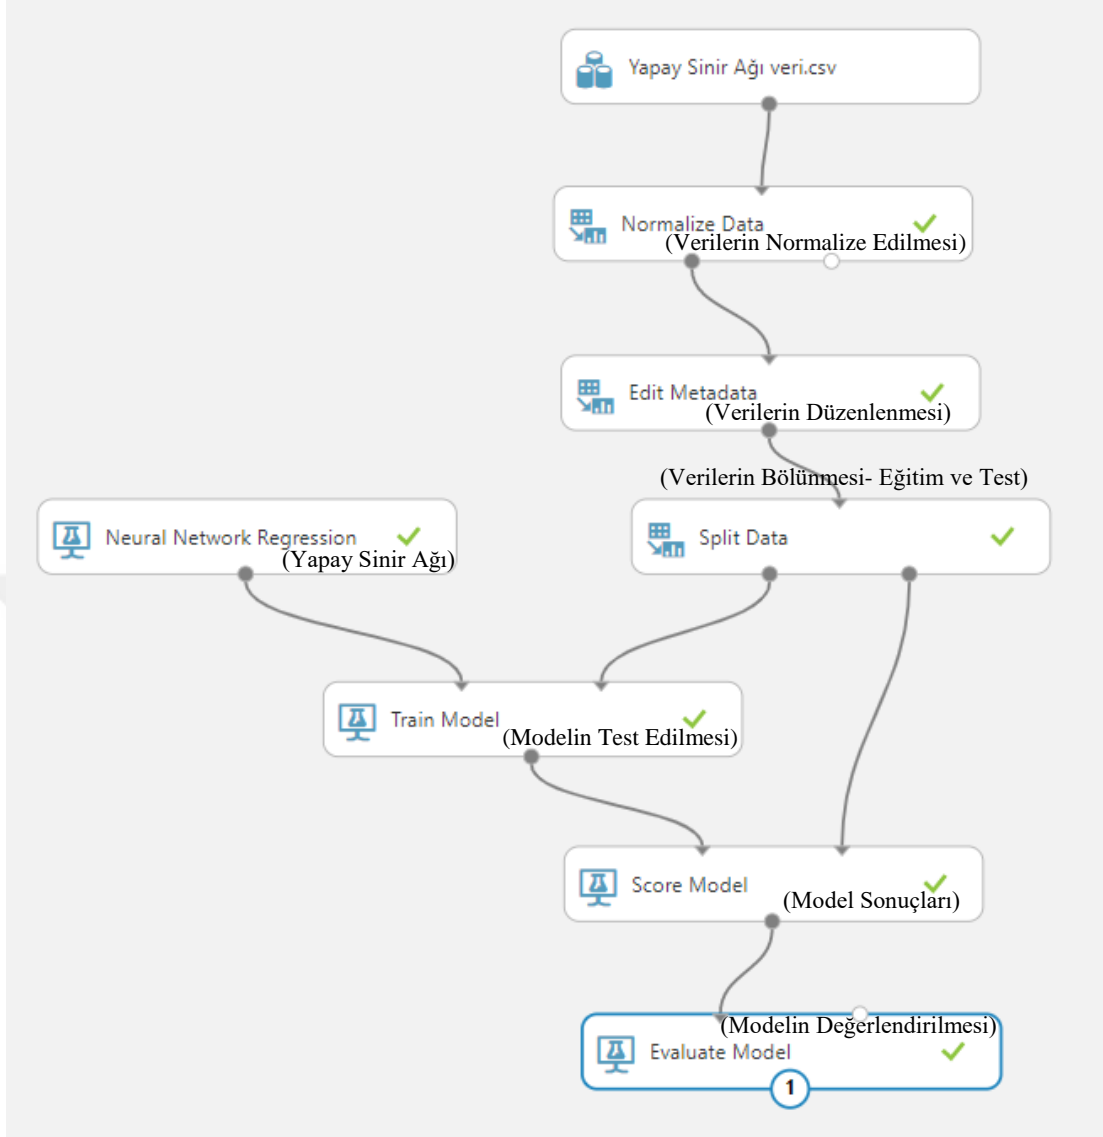
Bu tez çalışmasında ileri beslemeli çok katmanlı yapay sinir ağı modeli Microsoft Azure Machine Learning Studio (AMLS) ile firmanın 2020-2022 yılları arası 52866 adet üretim verisi üzerine uygulanmıştır. Bu verilere ek olarak bir önceki aşamada hesaplanan gecikme durumu değişkeni yapay sinir ağı modeline bağımsız bir değişken olarak eklenmiştir.

Çalışma kapsamında geliştirilen ağ modelinde değişkenler hammaddeye, üretim sürecine ve çıktılara dair değişkenler olmak üzere üç sınıfa ayrılmıştır. Üretimde kullanılan hammadde miktarı, çalışan sayısı, vardiya olup olmaması, hammadde stoku, faaliyet ayı sürece dair veriler olarak, tedarik gecikmesi durumu da hammadde tedarikğine dair değişken olarak ele alınmıştır. Çıktı olarak ise üretim miktarı kullanılmıştır. Ön şişirme ve blok bölümüne ait 18 adet değişken ve 52.866 adet veriden oluşan bu veri setinin %70’i yapay sinir ağının eğitiminde, %30’u ise yapay sinir ağının test edilmesi için kullanılmıştır. Bu doğrultuda geliştirilen ileri beslemeli çok katmanlı yapay sinir ağı yapısı Şekil 2.5’te gösterilmiştir:



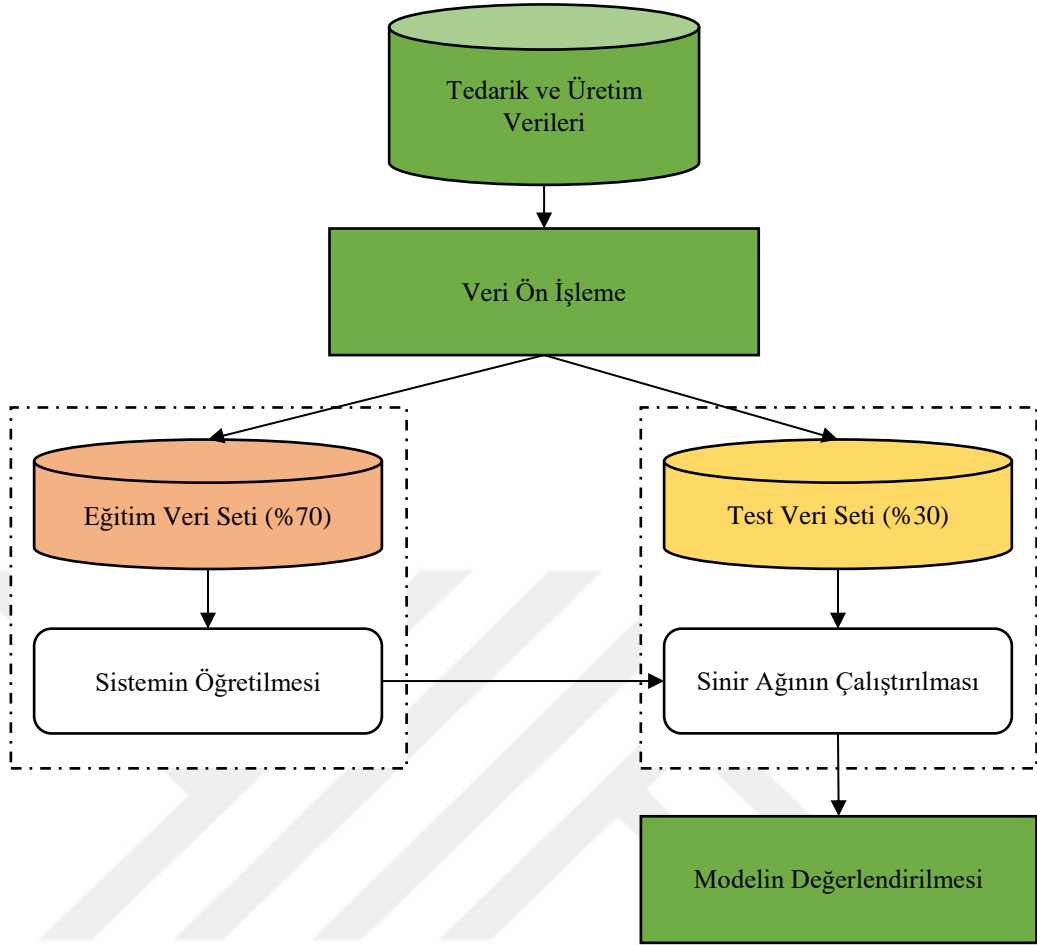
Şekil 2. 5. Geliştirilen İleri Beslemeli Çok Katmanlı Yapay Sinir Ağı Yapısı

Şekil 2.5'te gösterilen yapay sinir ağı modeli Microsoft Azure Machine Learning Studio Platformunda makine öğrenmesi algoritması ile çözülürken modelin eğitilmesi ve test edilmesine dair süreçte ait adımlar Şekil 2.6'da gösterilmiştir.



Şekil 2. 6. Microsoft Azure Machine Learning Studio Yapay Sinir Ağı Akışı

Veriler ön işleme kısmında incelenmiş, eksik veri ve aykırı veriler olmadığı tespit edilmiştir. Devamında stok miktarı, üretimde kullanılan hammadde miktarı ve ürün miktarı gibi değişkenler yüksek değerler olduğu için normalize edilmiştir. Veriler eğitim (%70) ve test verisi (%30) olarak iki gruba ayrılarak yapay sinir ağı modeli uygulanmıştır. Makine öğrenmesi uygulaması olarak ele alınan ileri beslemeli çok katmanlı yapay sinir ağı uygulamasında kullanılan adımlar Şekil 2.7’de sunulmuştur:



Şekil 2. 7. Çalışmanın Uygulama Adımları

Uygulama gerçekleştirilirken ilk olarak değişkenlere dair verilerin düzenlenmesi, dönüştürülmesi, eksik ve aykırı verilerin düzenlenmesi işlemleri yani veri ön işleme adımı gerçekleştirilmiştir. Bu aşamada hazırlanan veriler microsoft excel üzerinde virgülle ayrılarak cvs formatına dönüştürülmüştür. Ardından Microsoft Azure Machine Learning Studio platformuna dataset -> new dataset adımları ile yüklenmiştir. Yüklenen verilerin %70'u sistemin öğretilmesi için eğitim verisi, %30'u ise test verisi olarak ayarlanmıştır. İşletmenin 800 birim ürün depolayabildiği bilgisi bulunmaktadır. İşletme stoğa üretim yaptığı için bazı günler üretim olmamış bu durum bir kategorik değişken olarak modele eklenmiştir. Çalışan sayısının 16 çalışandan fazla olduğu durumda vardiyalı üretim yapılmaktadır. Bu nedenle vardiya durumu bir kategorik değişken olarak modele eklenmiştir. İşletmenin üretim ve hammadde hareketlerine dair 2021 ve 2022 yılları arasındaki değişken ve bu değişkenlere ait verilerin bir kesiti Tablo 2.13'te sunulmuştur.

Tablo 2. 13. Üretim Sürecine Dair Verilerin Bir Kesiti ve Yapay Sınır Ağı Modelinde Yer Alanlar

Hammadde	Vardiya (Y/V)	Çalışan Sayısı	Üretimde Kullanılan Miktar (Kg)	Ay	Üretilen Ürün Miktarı	Tedarik Gecikmesi (Y/V)	Gelen Hammadde (Kg)	Hammadde Stok Miktarı (Kg)	İstenen Ürün Yoğunluğu (kg/m ³)	İstenen Ürün Hacmi (m ³)	Tarih	Yıl
X	0	16	3375	Ocak	260	0	0	349.125	13	6.25	5.01.2021	2021
X	0	16	1125	Ocak	87	0	0	348.000	13	6.25	6.01.2021	2021
X	0	0	0	Nisan	0	1	13.500	361.500	13	6.25	8.04.2021	2021
X	0	16	10125	Nisan	779	1	0	351.375	13	6.25	12.04.2021	2021
X	0	0	0	Nisan	0	1	24.750	376.125	13	6.25	15.04.2021	2021
X	0	0	0	Nisan	0	1	99.000	475.125	13	6.25	16.04.2021	2021
X	0	0	0	Nisan	0	1	74.250	549.375	13	6.25	17.04.2021	2021
X	0	0	0	Nisan	0	1	49.500	598.875	13	6.25	19.04.2021	2021
X	1	24	24750	Nisan	1.904	1	0	574.125	13	6.25	22.04.2021	2021
X	0	16	18000	Nisan	1.385	0	0	556.125	13	6.25	23.04.2021	2021
X	0	16	22500	Nisan	1.731	0	0	533.625	13	6.25	24.04.2021	2021
X	1	24	36000	Nisan	2.769	0	0	497.625	13	6.25	25.04.2021	2021
X	0	0	0	Nisan	0	1	74.250	571.875	13	6.25	26.04.2021	2021
X	0	16	21375	Nisan	1.644	0	49500	600.000	13	6.25	27.04.2021	2021
X	0	16	23625	Nisan	1.817	1	0	576.375	13	6.25	28.04.2021	2021
X	0	16	12375	Nisan	952	1	24.750	588.750	13	6.25	29.04.2021	2021
X	1	24	27000	Nisan	2.077	0	24.750	586.500	13	6.25	30.04.2021	2021
X	0	16	16875	Mayıs	1.298	0	0	569.625	13	6.25	4.05.2021	2021
.
X	0	16	18000	Mayıs	1.385	1	0	551.625	13	6.25	5.05.2021	2021

Sisteme veriler yüklendikten sonra yapay sinir ağı modeli kurulmuştur. En iyi sonucu elde etmek için farklı öğrenme seviyeleri, iterasyon sayısı, gizli katman değerleri ve momentum değerleri denenmiştir. Yapılan denemelerde kullanılan söz konusu değerler ve sonuçları Tablo 2.14’te gösterilmiştir:

Tablo 2. 14. Denenen Yapay Sinir Ağı Modellerinden Bir Kesit

Model	Öğrenme Seviyesi	İterasyon Sayısı	Gizli Katman Sayısı	Momentum Değeri	Sonuç
Model I	0.005	5000	150	0.81	MAE=0,005 MSE=2886,73 R ² =0,9999
Model II	0.005	6000	200	0.85	MAE=0,009 MSE=1635,87 R ² =0,9998
Model III	0.010	4000	100	0.75	MAE=0,006 MSE=583,37 R ² =0,9991
Model IV	0.005	6000	100	0.85	MAE=0,004 MSE=1319,68 R ² =0,9999
Model V	0.010	5000	150	0.84	MAE=0,007 MSE=508,54 R ² =0,9989
Model VI	0.010	6000	200	0.80	MAE=0,009 MSE=512,19 R ² =0,9997
Model VII	0.005	6000	150	0.81	MAE=0,005 MSE=2886,73 R ² =0,9997
Model VIII	0.010	6000	150	0.82	MAE=0,015 MSE=510,63 R ² =0,9967

Denetimli makine öğrenmesi algoritması olarak geliştirilen ileri beslemeli yapay sinir ağı modeli kapsamında farklı özellikte sekiz ayrı model denenmiştir. Denenen her bir modele ait ortalama mutlak hata (MAE), ortalama mutlak hata kareleri (MSE) ve belirlilik katsayısı (R²) değerleri hesaplanmıştır.

MAE değerlerine göre değerlendirildiğinde optimum modelin Model IV (MAE=0.004) olduğu görülmektedir. Diğer modeller ise gerçek üretim değerine en yakın sonucu verenden en uzak sonucu verene doğru Model I (0,005) ve Model VII (0,005), Model III (0,006), Model V (0,007), Model II (0,009) ve Model VI (0,009) ve en son olarak Model VIII (0,015) şeklinde sıralanmıştır.

MSE değerlerine göre geliştirilen modeller sıralandığında optimum modelin Model V (MSE=508,54) olduğu görülmektedir. Diğer modeller ise gerçek üretim değerine en yakın sonucu verenden en uzak sonucu verene doğru Model VIII (510,63), Model VI (512,19), Model III (583,37), Model IV (1319,68), Model II (1635,87) ve Model I (2886,73) ile Model VII (2886,73) şeklinde sıralanmıştır.

R2 değerlerine göre modeller sıralanacak olursa gerçek üretim değerlerine en yakın sonucu verenden en uzak sonucu veren modele doğru Model I ve Model IV (0,9999), Model II (0,9998), Model VII (0,9997), Model IV (0,9994), Model III (0,9991), Model III (0,9991), Model V (0,9989) ve son olarak ise Model VIII (0,9967) olarak belirlenmiştir.

Sisteme tanıtılan veri seti ile yapılan denemeler sonucunda MAE değerlerine göre optimum değeri veren modelde öğrenme seviyesi 0.010, iterasyon sayısı 5000, gizli katman sayısı 150 ve momentum değeri 0.84 olarak belirlenmiştir. Bu uygulama sonucunda ortalama mutlak hata (MAE) 0.004 ve belirleme katsayısı (R^2) ise 0.9994 olarak bulunmuştur. MAE değerinin geliştirilen modeller içerisinde minimum olması ve R^2 değerinin bire oldukça yakın olmasından dolayı optimum model olarak Model IV belirlenmiştir. Model IV'te yapılan analizler neticesinde işletmenin gerçekleştirmiş olduğu üretim seviyesi ve modelin tahmin ettiği üretim seviyesi Tablo 2.15'te sunulmuştur:

Tablo 2. 15. Yapay Sinir Ağı Uygulama Sonuçları

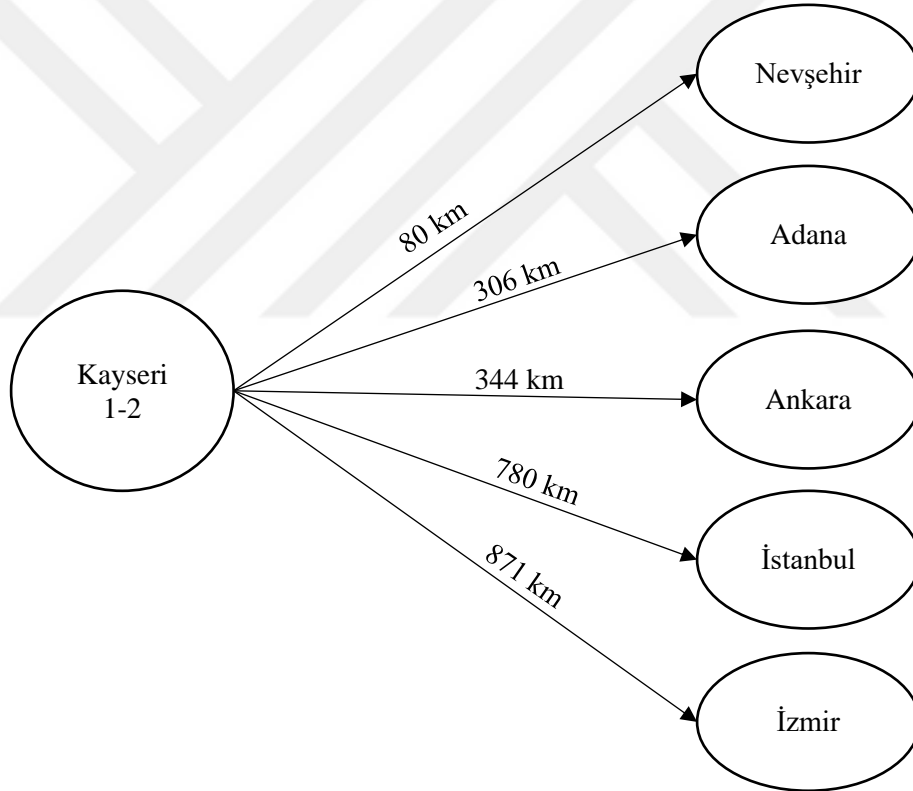
Tarih	Gerçekleşen Üretim	Tahmin Edilen Üretim	Ortalama Mutlak Hata
Nisan 2021	1817	1816.99	0.01
Mayıs 2021	2076	2076.00	0.00
Ekim 2021	519	519.00	0.00
Haziran 2021	951	951.00	0.00
Şubat 2022	1211	1210.99	0.01
Mayıs 2022	1038	1037.99	0.01
Haziran 2022	951	950.99	0.01
Temmuz 2022	2336	2335.99	0.01
Ağustos 2022	346	345.99	0.01

Bu tez çalışması kapsamında geliştirilen yapay sinir ağı modeli ile elde edilen üretim miktarı tahminleri karşılaştırıldığında 0.004 ortalama mutlak hata ve 0.9994 değerinde belirlilik katsayısı değerine ulaşılması geliştirilen modelin başarısını göstermektedir.

Gerçeğe oldukça yakın değerler elde edilmesinden dolayı eğitilen yapay sinir ağı modeli uygulanabilir bir başarı ortaya koymuştur.

2.5.3. Ürün Dağıtımını için Varsayımsal Bir Doğrusal Programlama Modeli

Bu tez çalışmasının buraya kadar olan kısmında gerçek veriler kullanılmış; bir tedarik zincirinin bir bütün olarak ele alınabilmesi için bundan sonraki kısım gerçek dünya şartlarına dayandırılarak varsayımsal olarak tasarlanmıştır. Bu doğrultuda işletmenin ürettiği ürünleri beş farklı ilde yer alan depolara dağıtmak için toplam 800 birim kapasiteli iki imalat yerinde deposunun olduğu varsayılmıştır. Söz konusu depolar ve dağıtım merkezlerini gösteren şema Şekil 2.8’de gösterilmiştir:



Şekil 2. 8. Depolar ve Dağıtım Merkezleri

İşletme stoğa üretim yaptığı için ürün stok miktarı sabit olarak 5000 m³ ve 10.400 kg toplam hacim ve ağırlığa sahiptir. Adet olarak ise yapılan hesaplamalar sonucunda 800 birim stok tuttuğu belirlenmiştir. Çalışmanın bundan sonraki kısmında işletmenin ürettiği ürünleri depolara dağıtmasına dair bir doğrusal programlama modeli geliştirilmiştir. Modele dair diğer bilgiler Tablo 2.16’da verilmiştir:

Tablo 2. 16. Taşıma Maliyetleri, Kapasiteler ve İhtiyaçlar

İmalathaneler	Depolar					Kapasite
	Kayseri	Nevşehir	Adana	Ankara	İstanbul	
Kayseri 1	4	10	11	18	20	500
Kayseri 2	5	9	12	17	21	300
İhtiyaçlar	80	110	160	240	210	800

İşletmenin verilen bilgiler eşliğinde taşıma maliyetlerini minimum yaparak depoların taleplerini karşılaması istenmektedir. Bu doğrultuda amaca yönelik şu model geliştirilmiştir:

X_{ij} : i. İmalathaneden j. depoya taşıma maliyeti (i=1,2; j=1,2,3,4,5)

$$\begin{aligned} \text{Min}C &= 4X_{11} + 10X_{12} + 11X_{13} + 18X_{14} + 20X_{15} + 5X_{21} + 9X_{22} + 12X_{23} \\ &+ 17X_{24} + 21X_{25} \end{aligned}$$

$$X_{11} + X_{12} + X_{13} + X_{14} + X_{15} \leq 500$$

$$X_{21} + X_{22} + X_{23} + X_{24} + X_{25} \leq 300$$

$$X_{11} + X_{21} \geq 80$$

$$X_{12} + X_{22} \geq 110$$

$$X_{13} + X_{23} \geq 160$$

$$X_{14} + X_{24} \geq 240$$

$$X_{15} + X_{25} \geq 210$$

$$X_{ij} \geq 0$$

Ulaştırma maliyetlerini minimize etmek amacıyla kurulan doğrusal programlama modeli LİNDİO paket programı ile çözülmüş ve 7 iterasyonda elde edilen optimum sonuçlar şu şekilde elde edilmiştir:

$$\text{Min}C=11400 \text{ TL } (X_{11}=80, X_{13}=160, X_{14}=50, X_{15}=210, X_{22}=110, X_{24}=190)$$

Elde edilen optimum sonuca göre üretilen ürünlerin beş ile dağıtımına dair tablo şu şekilde oluşmuştur:

Tablo 2. 17. Elde Edilen Sonuçlar ve Dağıtım Miktarları

İmalathaneler	Depolar					Kapasite
	Kayseri	Nevşehir	Adana	Ankara	İstanbul	
Kayseri 1	80	-	160	50	210	500
Kayseri 2	-	110	-	190	-	300
İhtiyaçlar	80	110	160	240	210	800

Geliştirilen doğrusal programlama modeli sonucunda işletmenin beş farklı ilde bulunan dağıtım noktalarına taşınması minimum 11400 TL ile olmakta; Nevşehir, Adana ve Ankara illerinin talepleri birinci depodan karşılanmaktadır. İzmir ilinin talep miktarı ise ikinci depodan karşılanırken İstanbul ilinin talep miktarı birinci ve ikinci depodan karşılanmaktadır.

2.6. SONUÇ

Tedarik zinciri yönetimi, 2011’de ilan edilen son sanayi devrimi ile birlikte dijitalleşmenin etkisinin en fazla görüldüğü sektörlerin başında gelmektedir. Bu doğrultuda işletmeler tüm zincir ağı boyunca dijital teknolojileri içeren unsurları yoğun olarak kullanmaktadır. Tüm süreç içerisinde yer alan verileri doğru ve etkili analiz ederek faydalı sonuçlar çıkarmak tüm zincirin başarısının yanında tedarik zinciri ağı içerisinde yer alan tüm işletmelerin başarısını da ayrı ayrı etkilemektedir.

Günümüz tedarik zincirleri artık üretilen bir ürün zincirin son halkasında tüketiciyle buluştuğu andan itibaren hammadde tedarikçisine kadar bilgi akışı içeren bir süreç haline gelmiştir. Bir mağazada ilgili ürün, tüketiciye satıldığında önce üretici firmaya satıcının elindeki stoğun azaldığı bilgisi gidecek ve üretim planlaması bu bilgiye göre gerçekleşecektir. Yine aynı şekilde üretim alanlarında faaliyetlerin başlaması sonucunda üreticinin sahip olduğu hammadde miktarı azalacak bu durumda hammadde tedarikçisinin olası siparişe karşı hammadde hazırlığına başlamasına neden olacaktır. Yine tüketicilerden geri dönüşler çerçevesinde ürün niteliğindeki geri dönütlerin tüm zincir boyunca iletilmesi zincirin başarısını doğrudan etkilemektedir. Tüm bu açıklamalardan yola çıkarak süreçte kullanılan sensörler aracılığıyla bilgilerin

toplanması, dağıtılması ve işlenmesi nesnelerin internetini tedarik zincirlerine dahil etmektedir. Bu durumda dijital tedarik zincirleri ya da IoT tabanlı tedarik zincirlerini ortaya çıkarmakta ve klasik tedarik zincirlerinden günümüz tedarik zincirlerini farklılaştırmaktadır.

Dijital tedarik zinciri yönetimi, birbirinden ayrı olan uygulamaların ve farklı tesislerin tedarik zinciri ağı boyunca sistematik bir biçimde birbirine sanal ağlar ile bağlandığı yapıdır. Esnek bir yapı haline gelen ve dinamik forma dönüşen tedarik zincirlerinde, ağ içerisinde yaşanan problemler ve iş akışları oldukça karmaşık bir hale gelmiştir. Dünya çapında faaliyet gösteren şirketler bile artık yazılımsal olarak birbirine bağlı ve eş zamanlı bilgi akışının olduğu, farklı yerler arasında üretilen, satılan ve depolanan ürünlere dair bilgilerin paylaşıldığı dijital bir zincir haline gelmiştir. İleri teknoloji kullanılmaya başlanmasıyla birlikte hammaddelerin taşıma yollarının gelişmesi, dünyanın herhangi bir yerine ürünler gönderilmesi, internet üzerinden satışlar alanı ulusal bazdan küresel bir yapıya dönüştürmüştür. Çevrimiçi olarak tüketicilerin ürünler satın alması, gelişen teknolojik araçların tedarik zinciri ağı içerisine entegre edilmesi, sürekli olarak sağlanan büyük veri analizi işletmeleri zincirler üzerinde büyük veri analitiği yapmaya zorunlu kılmıştır. Yaşanan bu zorunluluk ile beraber geleneksel tedarik zinciri yönetiminden IoT tabanlı tedarik zincirine doğru bir evrim hızlı bir şekilde olmuş; bu anlamda yapılacak analizler ve büyük veri kullanımı işletmeler için sürdürülebilir değer yaratan ve aynı sektörde faaliyet gösteren işletmelere karşı önemli bir rekabet avantajı sağlayan önemli bir süreç haline gelmiştir. Bu noktada elde edilen büyük verilerin analiz edilmesi klasik yöntemler ile mümkün halden çıkmış ve yapay zeka tabanlı makine öğrenmesi algoritmaları geliştirilmiştir.

Makine öğrenmesi, veri madenciliğiyle yakın ilişkili olarak geliştirilen, bilgisayarların bireylerin düşünce yapısına benzer bir şekilde öğrenmelerine yönelik yöntemleri içeren bilim alanıdır. Bir yapay zeka uygulama alanı olan makine öğrenmesinin amacı, daha kesin tahminlerde bulunarak daha olumlu sonuçlar elde etmektir. Bu doğrultuda verilerin etiketlenmiş olmasına bağlı olarak denetimli, denetimsiz, yarı denetimli ve takviyeli makine öğrenmesi algoritmaları geliştirilmiştir. Bu tez çalışması kapsamında kullanılan veriler etiketli veriler olduğu için uygulama metodolojisinde yer alan yöntemler birer denetimli makine öğrenmesi algoritmasıdır.

Bu tez çalışması kapsamında ısı yalıtım grubu ürünler üreten bir firmadan ön şişirme ve blok bölümünde üretilen bir ürün grubuna dair hammadde sipariş sürecine ve üretim sürecine dair büyük veriler alınarak makine öğrenmesi algoritmaları ile analiz edilmiştir. Bu kapsamda çalışmanın uygulama bölümü, bir tedarik zincirinin aşamaları göz önüne alınarak hammadde tedarik süreci, üretim süreci ve dağıtım süreci olmak üzere üç kısım olarak tasarlanmıştır. Bu şekilde hammadde temininden, ürünlerin üretilerek satış noktalarına dağıtılmasına kadar olan tüm tedarik zinciri süreci incelenmiştir. Firmanın ön şişirme ve blok bölümünde makinelere entegre sensörler ve IoT aygıtları aracılığıyla 18 adet değişkene ait 52.866 adet veri elde edilerek analizlerde kullanılmıştır.

Bu tez çalışmasında; IoT Tabanlı tedarik zinciri yönetiminde, büyük verilerin makine öğrenmesi yöntemleri ile analiz edilerek, yapay zekâya dayalı akıllı bir tedarik zinciri ağ tasarımı yapılması ve bu doğrultuda tüm tedarik zinciri sürecinin bir bütün olarak değerlendirilmesinin yapılması amaçlanmıştır. Tedarik zinciri yönetimi alanında sensörler ve teknolojinin kullanılarak IoT tabanlı tedarik zinciri yönetimi üzerine çalışmaların az olması ve literatürde makine öğrenmesi yöntemleri ile tedarik zinciri ağlarının bir bütün olarak incelenmesi probleminin ele alınmamış olması çalışmayı önemli kılmaktadır.

Tedarik ve üretim süreçlerine dair analizler uygulanmadan önce değişkenler arasında anlamlılığın ve ilişkilerin belirlenmesi amacıyla betimleyici istatistikler, korelasyon ilişkileri ve regresyon analizi uygulanmıştır. Bu doğrultuda H_1 ve H_2 hipotezleri test edilmiştir. Uygulanan korelasyon analizi sonuçlarına göre bağımlı değişken olan teslim süresi değişkeni üzerinde etki büyüklüğüne göre bağımsız değişkenler gelen hammadde miktarı (0,657) ve mesafe (0,106) olarak belirlenmiştir. Söz konusu değişkenler arasındaki ilişkiler %1 düzeyinde anlamlı olarak tespit edilmiştir ve bu doğrultuda “ H_1 : Gelen hammadde miktarı ve taşıma mesafesi ile teslim süresi arasında pozitif yönlü bir ilişki vardır.” Hipotezi kabul edilmiştir. Devamında uygulanan regresyon analizi sonucunda ise “ H_2 : Tedarik sürecine dair özellikler, teslim süresi üzerinde etkilidir.” kabul edilmiştir. Yani, hammadde temininde rol oynayan tedarikçi seçimini;, mesafe, gelen hammadde miktarı, hava durumu ve faaliyet ayından oluşan

tedarik sürecine dair özellikler teslim süresi üzerinde etkili olduğu belirlenmiştir. Ayrıca, regresyon modelinde kullanılan tedarikçi, mesafe, hava durumu, gelen hammadde miktarı ve ay değişkenlerinden oluşan bağımsız değişkenlerin, teslim süresi olarak belirlenen bağımlı değişkenin %77'sini açıkladığı tespit edilmiştir ($R^2=0,770$).

Değişkenlere dair betimleyici istatistiklerin sunulması ve birbirleri ile ilişkilerinin belirlenmesine yönelik analizler yapılmıştır. Devam eden kısım makine öğrenmesi uygulamasının ilk kısmı olarak tasarlanmıştır. Bu kapsamda tedarikçilerden istenen hammaddelerin geliş süreleri belirlenmiş ve yapılan analizler neticesinde makine öğrenmesi ile siparişler girilerek teslim süreleri tahmin edilmiştir. Bu verileri elde etmek işletmelerin ani talepler ve ani gelişen durumlar karşısında planlama yapabilmesine olanak tanımaktadır. Bu doğrultuda işletmenin tedarikçilerinin hammaddeleri teslim etme süresi ortalama 2,19 gün olarak belirlenmiştir. Tedarikçi bağlamında ise Tedarikçi I'den iyi hava ve yol koşullarında 1,5 günde, kötü hava şartlarında ise 3,1 günde teslimat gerçekleşmektedir. Tedarikçi II'den ise iyi hava ve yol koşullarında 2,75 günde, kötü hava şartlarında ise 4,25 günde teslimat gerçekleşmektedir. Bu rakamlar Tedarikçi III'den talep edilen hammaddelerde ise sırasıyla 3,84 ve 5,34'dür. Makine öğrenmesi uygulaması sonucunda elde edilen sonuçlara göre hammadde tedarikçilerinden gelen siparişlerin teslim süresi doğru bir planlama neticesinde yaklaşık olarak 1 gün daha erken olacağı tespit edilmiştir.

Bu tez çalışmasının ikinci kısmında ise geliştirilen yapay sinir ağı modeli ile gerçekleşen üretim seviyesi ile makine öğrenmesi uygulamasının tahmin ettiği üretim seviyesi karşılaştırılarak ortalama standart hata (MAE), Ortalama hata kareleri (MSE) ve belirlilik katsayısı (R^2) değerleri belirlenmiştir. Denetimli makine öğrenmesi algoritması olarak geliştirilen ileri beslemeli yapay sinir ağı modeli kapsamında farklı özellikte sekiz ayrı model denenmiştir. Kullanılan veriler ile geliştirilen modele göre yapılan analizler neticesinde işletmenin gerçek üretim verileri ile eğitilen yapay sinir ağı modelinin birbirine yakın olduğu görülmektedir. Denenen her bir modele ait ortalama mutlak hata (MAE), ortalama mutlak hata kareleri (MSE) ve belirlilik katsayısı (R^2) değerleri hesaplanarak şu sonuçlar elde edilmiştir:

- MAE değerlerine göre değerlendirildiğinde en optimum modelin Model IV (MAE=0.004) olduğu görülmektedir. Diğer modeller ise gerçek üretim değerine en yakın sonucu verenden en uzak sonucu verene doğru Model I (0,005) ve Model VII (0,005), Model III (0,006), Model V (0,007), Model II (0,009) ve Model VI (0,009) ve en son olarakta Model VIII (0,015) şeklinde sıralanmıştır.
- MSE değerlerine göre geliştirilen modeller sıralandığında en optimum modelin Model V (MSE=508,54) olduğu görülmektedir. Diğer modeller ise gerçek üretim değerine en yakın sonucu verenden en uzak sonucu verene doğru Model VIII (510,63), Model VI (512,19), Model III (583,37), Model IV (1319,68), Model II (1635,87) ve Model I (2886,73) ile Model VII (2886,73) şeklinde sıralanmıştır.
- R^2 değerlerine göre modeller sıralanacak olursa gerçek üretim değerlerine en yakın sonucu verenden en uzak sonucu veren modele doğru Model I ve Model IV (0,9999), Model II (0,9998), Model VII (0,9997), Model IV (0,9994), Model III (0,9991), Model III (0,9991), Model V (0,9989) ve son olarak ise Model VIII (0,9967) olarak belirlenmiştir.

Son kısımda ise işletmenin ürün stok kapasitesinin 800 birim olduğundan yola çıkarak; iki farklı depodan beş farklı dağıtım merkezine talepler doğrultusunda dağıtım yapıldığı varsayılarak geliştirilen model LINDO paket programı ile çözülmüştür. Gerçekleştirilen analiz sonucunda işletmenin beş farklı ilde bulunan dağıtım noktalarına taşınması minimum 11400 TL ile olmakta; Ankara, İzmir ve Nevşehir illerinin taleplerinin tamamı birinci depodan karşılanırken İstanbul ilinin talebinin 50 birimi bu depodan karşılanmaktadır. Adana ilinin talebinin tamamı ile İstanbul ilinin talebinin 190 birimi ise ikinci depodan karşılanmaktadır.

Tedarik zinciri yönetiminde makine öğrenmesi uygulamaları oldukça güncel bir konu olmakla birlikte gittikçe yaygınlaşan bir literatüre sahiptir. İlgili literatür incelendiğinde talep tahmini (Carbonneau vd., 2008; Azadi vd., 2023; Hu vd., 2023), üretim miktarı tahmini (Cao vd., 2016; Li ve Han, 2017; Zhan vd., 2019; Wang vd., 2023) ve tedarik gecikmesi (Barros, 2023; Steinberg vd., 2023) konuları ağırlıklı olarak ele alınmıştır. Bu çalışma kapsamında ise bir ürün grubuna yönelik tedarik

zinciri yapısı bütüncül olarak ele alınmış, hammadde tedariki sürecinde yaşanan gecikmeler belirlenmiş ve bu durum bir değişken olarak üretim miktarının belirlenmesinde kullanılacak yapay sinir ağı modeline eklenmiştir. Devamında ise varsayımsal bir model geliştirilerek üretilen ürünlerin satışına yönelik bir doğrusal programlama modeli geliştirilmiştir. Bahsedilen bu yol ile tedarik zincirinde makine öğrenmesi uygulaması için bütüncül bir yapı oluşturularak literatüre katkı sağlanması amaçlanmıştır.

Bu çalışmanın tedarik zinciri yönetimini bir bütün olarak ele alması ve makine öğrenmesi algoritmaları kullanmasının yanında bazı kısıtları bulunmaktadır. Örneğin işletmeden yalnızca bir ürün grubuna dair kısıtlı veriler elde edilmiştir. Tüm süreçleri kapsayan veriler ile bu analizlerin yapılması ve hatta sensörler kullanılarak taşımacılık faaliyetlerinin takip edilerek analizler yapılması alanın gelişimine önemli katkı sağlayacaktır. Buna ek olarak her bir sürece dair daha uzun dönemli veriler kullanılarak süreç optimizasyonu yapılabilir. Gerçekleştirilecek analizler ile geleceğe dönük tahminler ile optimum bir tedarik zinciri yapısı, üretim planlama ve satış tahminleri yapılarak yöneticilere karar verme sürecinde katkıda bulunulabilir. Bir diğer yandan işletmelerin yeni ürün geliştirme ve pazar araştırması sürecinde makine öğrenmesi algoritmaları geliştirmesi ve kullanması işletmelerin yeni politikalar geliştirmesinde önemli rol oynamaktadır. Yeni ürün geliştirme sürecinde müşteri beklentilerinin belirlenmesi ve pazar konumlandırması için makine öğrenmesi tahminlerinin kullanılması, pazarların ihtiyacı olan ürünlerin özelliklerinin belirlenmesi ve doğru konumlandırılmasında önemli rol oynayacaktır. Belirtilen konularda makine öğrenmesi ile uygulamalar yapılabilir.

KAYNAKÇA

- Abbasi B, Babaei T, Hosseinifard Z, Smith-Miles K & Dehghani M (2020). Predicting solutions of large-scale optimization problems via machine learning: A case study in blood supply chain management. *Computers & Operations Research*, 119, 104941.
- Abdel-Basset M, Manogaran G & Mohamed M (2018). *Internet of Things (IoT) and its impact on supply chain: A framework for building smart, secure and efficient systems*. *Future Generation Computer Systems*, 86(9), 614-628.
- Abiodun OI, Jantan A, Omolara AE, Dada KV, Mohamed NA & Arshad H (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4(11), e00938.
- Abraham A (2005). *Artificial neural networks*. Handbook of measuring system design.
- Acar AZ & Köseoğlu AM (2014). Lojistik yaklaşımıyla tedarik zinciri yönetimi. *Nobel Yayınevi*.
- Agatonovic-Kustrin S & Beresford R (2000). Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. *Journal of pharmaceutical and biomedical analysis*, 22(5), 717-727.
- Ageron B, Bentahar O & Gunasekaran A (2020). *Digital supply chain: challenges and future directions*. In *Supply Chain Forum: An International Journal* (Vol. 21, No. 3, pp. 133-138). Taylor & Francis.
- Ajami A & Daneshvar M (2012). Data driven approach for fault detection and diagnosis of turbine in thermal power plant using Independent Component Analysis (ICA). *International Journal of Electrical Power & Energy Systems*, 43(1), 728-735.
- Akben İ & Avşar ÖGİİ (2017). *Digital Supply Chain and Cloud Computing*. El-Ruha, 104.
- Akter J (2014). Bootstrapped Durbin–Watson test of autocorrelation for small samples. *ABC Journal of Advanced Research*, 3(2), 137-142.
- Alam M (2012). *Cloud algebra for cloud database management system*. In *Proceedings of the Second International Conference on Computational Science, Engineering and Information Technology* (pp. 26-29).

- Alazemi FKA, Ariffin MKABM, Mustapha FB & Supeni EEB (2022). A new fuzzy TOPSIS-based machine learning framework for minimizing completion time in supply chains. *International Journal of Fuzzy Systems*, 24(3), 1669-1695.
- Almaslamani F, Abuhusein R, Saleet H, AbuHilal L & Santarisi N (2020). Using big data analytics to design an intelligent market basket-case study at sameh mall. *Int. J. Eng. Res. Technol*, 13(11), 3444-3455.
- Alpaydın E (2011). *Makine Öğrenmesi*. QNB Finansbank, Ufuk Açan Yayınlar.
- Alpaydin E (2021). *Machine learning*. Mit Press.
- Al Snousy MB, El-Deeb HM, Badran K & Al Khlil IA (2011). Suite of decision tree-based classification algorithms on cancer gene expression data. *Egyptian Informatics Journal*, 12(2), 73-82.
- Altıparmak F, Gen M, Lin L & Paksoy T (2006). A genetic algorithm approach for multi-objective optimization of supply chain networks. *Computers & industrial engineering*, 51(1), 196-215.
- Amanullah MA, Habeeb RAA, Nasaruddin FH, Gani A, Ahmed E, Nainar ASM, ... & Imran M (2020). Deep learning and big data technologies for IoT security. *Computer Communications*, 151, 495-517.
- Amasyalı MF (2008). Yeni makine öğrenmesi metotları ve ilaç tasarımına uygulamaları.
- Amin MF & Murase K (2009). Single-layered complex-valued neural network for real-valued classification problems. *Neurocomputing*, 72(4-6), 945-955.
- Anderson D & McNeill G (1992). Artificial neural networks technology. *Kaman Sciences Corporation*, 258(6), 1-83.
- Arumugam S, Rajak S, Vimal KEK, Parthiban J, Sivaraman SK, Kandasamy J & Duque AA (2022). Multi-objective mixed-integer linear optimization model for sustainable closed-loop supply chain network: A case study on remanufacturing steering column. *Environment, Development and Sustainability*, 24(5), 6481-6507.
- Atalay M & Çelik E (2017). Büyük veri analizinde yapay zekâ ve makine öğrenmesi uygulamaları-artificial intelligence and machine learning applications in big data analysis. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(22), 155-172.

- Atoui MA, Verron S & Kobi A (2016). A Bayesian network dealing with measurements and residuals for system monitoring. *Transactions of the Institute of Measurement and Control*, 38(4), 373-384.
- Avşar İİ (2021). Sayısal İkiz ve Tedarik Zinciri. *European Journal of Managerial Research (EUJMR)*, 5(9), 228-244.
- Azadi M, Yousefi S, Saen RF, Shabanpour H & Jabeen F (2023). Forecasting sustainability of healthcare supply chains using deep learning and network data envelopment analysis. *Journal of Business Research*, 154, 113357.
- Bacour C, Baret F, Béal D, Weiss M & Pavageau K (2006). Neural network estimation of LAI, fAPAR, fCover and LAI× Cab, from top of canopy MERIS reflectance data: Principles and validation. *Remote sensing of environment*, 105(4), 313-325.
- Bakoğlu R & Yılmaz E (2001). *Tedarik Zinciri Tasarımının Rekabet Avantajı Yaratması Açısından Değerlendirilmesi*. 6. Ulusal Pazarlama Kongresi.
- Ballou RH (1978). *Basic business logistics: transportation, materials management, physical distribution* (No. 2). Prentice Hall.
- Ballou, R. H. (1992). *Business Logistics Management*.
- Ballou RH (2007). The evolution and future of logistics and supply chain management. *European business review*.
- Barros JDL (2023). An intelligent decision support system for estimating supply lead times towards improved safety stock dimensioning.
- Bartlett MS (2001). Face image analysis by unsupervised learning (Vol. 612). *Springer Science & Business Media*.
- Baryannis G, Dani S & Antoniou G (2019). Predicting supply chain risks using machine learning: The trade-off between performance and interpretability. *Future Generation Computer Systems*, 101, 993-1004.
- Basak J & Krishnapuram R (2005). Interpretable hierarchical clustering by constructing an unsupervised decision tree. *IEEE transactions on knowledge and data engineering*, 17(1), 121-132.
- Başer A & Sert M (2021). Permeability Estimation for Natural State Modeling of Geothermal Fields with Machine Learning. In *2021 International Conference on INnovations in Intelligent SysTems and Applications (INISTA)* (pp. 1-5). IEEE.
- Batista GE & Monard MC (2002). A study of K-nearest neighbour as an imputation method. *HIS*, 87(251-260), 48.

- Belgiu M & Drăguț L (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS journal of photogrammetry and remote sensing*, 114, 24-31.
- Bello-Orgaz G, Jung JJ & Camacho D (2016). Social big data: Recent achievements and new challenges. *Information Fusion*, 28, 45-59.
- Ben-Hur A, Ong CS, Sonnenburg S, Schölkopf B & Rätsch G (2008). Support vector machines and kernels for computational biology. *PLoS computational biology*, 4(10), e1000173.
- Ben-Tal A, El Ghaoui L & Nemirovski A (2009). *Robust optimization* (Vol. 28). Princeton university press.
- Benton WC (2019). *Distributed function generation with shared structures*. U.S. Patent No. 10,241,767. Washington, DC: U.S. Patent and Trademark Office.
- Bezdek JC (1981). *Pattern recognition with fuzzy objective function algorithms*. New York: Plenum.
- Bhargava B, Ranchal R & Othmane LB (2013). *Secure information sharing in digital supply chains*. In 2013 3rd IEEE international advance computing conference (IACC) (pp. 1636-1640). IEEE.
- Biggio B, Nelson B & Laskov P (2012). *Poisoning attacks against support vector machines*. arXiv preprint arXiv:1206.6389.
- Bilgili L (2018). Gemi yaşam döngüsünde operasyonel gaz emisyonlarının makine öğrenmesi yöntemiyle tahmini (Doctoral dissertation).
- Bilgin B (2018). *Makine Öğrenmesi Algoritmaları*. Papatya Yayıncılık.
- Bishop CM & Nasrabadi NM (2006). *Pattern recognition and machine learning* (Vol. 4, No. 4, p. 738). New York: springer.
- Blazquez D & Domenech J (2018). Big Data sources and methods for social and economic analyses. *Technological Forecasting and Social Change*, 130, 99-113.
- Bokde D, Girase S & Mukhopadhyay D (2015). Matrix factorization model in collaborative filtering algorithms: A survey. *Procedia Computer Science*, 49, 136-146.
- Bonaccorso G (2017). *Machine learning algorithms*. Packt Publishing Ltd.
- Booker LB, Goldberg DE & Holland JH (1989). Classifier systems and genetic algorithms. *Artificial intelligence*, 40(1-3), 235-282.

- Bora DJ (2019). Big data analytics in healthcare: A critical analysis. *In Big Data Analytics for Intelligent Healthcare Management* (pp. 43-57). Academic Press.
- Borade AB & Bansod SV (2007). *Domain Of Supply Chain Management-A State Of Art*. *Journal of Technology Management & Innovation*, 2(4), 109-121.
- Bottou L & Vapnik V (1992). Local learning algorithms. *Neural computation*, 4(6), 888-900.
- Braganza A (2002). *Enterprise integration: creating competitive capabilities*. *Integrated Manufacturing Systems*, 13(8), 562-572.
- Branavan SR, Chen H, Zettlemoyer L & Barzilay R (2009). Reinforcement learning for mapping instructions to actions. *In Proceedings of the Joint Conference of the 47th Annual Meeting of the ACL and the 4th International Joint Conference on Natural Language Processing of the AFNLP* (pp. 82-90).
- Breiman L (1984). Introduction tree classification. *Classification and Regression Trees*, 18-55.
- Breiman L (2001). Random forests. *Machine learning*, 45, 5-32.
- Brewer PC (2000). An approach to organizing a management accounting curriculum. *Issues in accounting education*, 15(2), 211-235.
- Bulbul A, Cipiloglu Z & Capin T (2009). A face tracking algorithm for user interaction in mobile devices. *In 2009 International Conference on CyberWorlds* (pp. 385-390). IEEE.
- Burns, R. (2015). Rethinking big data in digital humanitarianism: Practices, epistemologies, and social relations. *GeoJournal*, 80, 477-490.
- Büyüközkan G & Göçer F (2018). *Digital Supply Chain: Literature review and a proposed framework for future research*. *Computers in Industry*, 97, 157-177.
- Byun H & Lee SW (2002). Applications of support vector machines for pattern recognition: A survey. *In Pattern Recognition with Support Vector Machines: First International Workshop, SVM 2002 Niagara Falls, Canada, August 10, 2002 Proceedings* (pp. 213-236). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Cain CA (1980). A theoretical basis for microwave and RF field effects on excitable cellular membranes. *IEEE Trans. Microw. Theory Tech.* 28, 142–147.
- Calatayud A, Mangan J & Christopher M (2019). The self-thinking supply chain. *Supply Chain Management: An International Journal*, 24(1), 22-38.

- Camastra F & Vinciarelli A (2008). Feature extraction methods and manifold learning methods. *Machine Learning for Audio, Image and Video Analysis: Theory and Applications*, 305-341.
- Candan F, Emir S, Doğan M & Kumbasar T (2018). Labyrinth Problem Solution with Reinforcement Q-Learning Method. *TOK2018 Otomatik Kontrol Ulusal Toplantısı*, Kayseri.
- Carbonneau R, Laframboise K & Vahidov R (2008). Application of machine learning techniques for supply chain demand forecasting. *European Journal of Operational Research*, 184(3), 1140-1154.
- Cavalcante IM, Frazzon EM, Forcellini FA & Ivanov D (2019). A supervised machine learning approach to data-driven simulation of resilient supplier selection in digital manufacturing. *International Journal of Information Management*, 49, 86-97.
- Ceyhan H & Kasapbaşı MC (2022). Üretim sistemlerinde makine öğrenmesi ile kestirimci bakım uygulaması ve modellemesi. *Avrupa Bilim ve Teknoloji Dergisi*, (33), 167-175.
- Chakrabarti D, Kumar R & Tomkins A (2006). Evolutionary clustering. *In Proceedings of the 12th ACM SIGKDD international conference on Knowledge discovery and data mining* (pp. 554-560).
- Chandra C & Tumanyan A (2005). *Supply chain system taxonomy: a framework and methodology*. *Human Systems Management*, 24(4), 245-258.
- Chao WH, Lai HY, Chen YY, Lin SH, Lo YC, Tsang S, Chen SY, ... & Jaw FS (2011). Automatic spike sorting for extracellular electrophysiological recording using unsupervised single linkage clustering based on grey relational analysis. *Journal of neural engineering*, 8(3), 036003.
- Charles V & Gherman T (2013). Achieving competitive advantage through big data. *Strategic implications*. *Middle-East Journal of Scientific Research*, 16(8), 1069-1074.
- Chaudhary K & Alam M (2022). *Big Data Analytics: Applications in Business and Marketing*. Auerbach Publications.
- Chen H, Chiang RH & Storey V. (2012). Business intelligence and analytics: From big data to big impact. *MIS quarterly*, 1165-1188.

- Chen WY, Liu YC, Kira Z, Wang YCF & Huang JB (2019). *A closer look at few-shot classification*. arXiv preprint arXiv:1904.04232.
- Cheng X, Fang L, Hong X & Yang L (2017). Exploiting mobile big data: Sources, features, and applications. *IEEE Network*, 31(1), 72-79.
- Chiang YM, Chang LC & Chang FJ (2004). Comparison of static-feedforward and dynamic-feedback neural networks for rainfall–runoff modeling. *Journal of hydrology*, 290(3-4), 297-311.
- Chopra S, Meindl P & Kalra DV (2007). *Supply Chain Management* by Pearson. *Pearson Education India*.
- Christopher M (1992). *Logistics and Supply Chain Management*. Pitman Publishing. London, Edition, 13, 343-376.
- Cooper MC, Douglas ML & Janus DP (1997). Supply Chain Management: More Than a New Name for Logistics. *The International Journal of Logistics Management*, Vol.8No.1, pp.1–14.
- Council SC (2008). *Supply chain operations reference model*. Overview of SCOR version, 5(0).
- Cox BA, Preston JF, Rebeiz PP & Breitbach T (2021). Developing a resilient, robust and efficient supply network in Africa. *Journal of Defense Analytics and Logistics*, 5(2), 224-241.
- Cox M & Ellsworth D (1997). Managing big data for scientific visualization. In *ACM siggraph* (Vol. 97, No. 1, pp. 21-38). MRJ/NASA Ames Research Center.
- Croxton KL, Garcia-Dastugue SJ, Lambert DM & Rogers DS (2001). *The supply chain management processes*. *The international journal of logistics management*, 12(2), 13-36.
- Çelik C & Yelkikalan N (2021). Makine Öğrenme Yöntemlerinin Depo Yönetim Süreçlerinde Uygulanması: Azure ML Studio Örneği. *Yaşar Üniversitesi E-Dergisi*, 16(62), 659-682.
- Çelik Ö (2018). *A research on machine learning methods and its applications*. *Journal of Educational Technology and Online Learning*, 1(3), 25-40.
- Çizmeçi, F. (2002). Tedarik zinciri yönetimi. *Alfa Basım Yayım*, 1.
- Dahlgaard JJ & Dahlgaard-Park S (2006). Lean production, six sigma quality, TQM and company culture. *The TQM magazine*, 18(3), 263-281.

- Dai HN, Wang H, Xu G, Wan J & Imran M (2020). Big data analytics for manufacturing internet of things: opportunities, challenges and enabling technologies. *Enterprise Information Systems*, 14(9-10), 1279-1303.
- Daldır I (2021). Havacılık sektöründe uçuş gecikmelerinin makine öğrenmesi temelli analizi ve tahmini.
- Damodar N & Porter DC (2020). Çev. Şenesen Ü & Şeneen GG. Temel Ekonometri. Literatür Yayıncılık.
- Daponte P & Grimaldi D (1998). Artificial neural networks in measurements. *Measurement*, 23(2), 93-115.
- Dash M, Liu H, Scheuermann P & Tan KL (2003). Fast hierarchical clustering and its validation. *Data & Knowledge Engineering*, 44(1), 109-138.
- Davenport TH, Barth P & Bean R (2012). *How 'big data' is different*.
- Demirtaş B & Arğan M (2015). Big data and change in marketing: A theoretical approach. *Journal of Marketing and Marketing Research*, 15, 1-21.
- Dey A, Singh J & Singh N (2016). Analysis of supervised machine learning algorithms for heart disease prediction with reduced number of attributes using principal component analysis. *International Journal of Computer Applications*, 140(2), 27-31.
- Dhaya R, Kanthavel R, Algarni F, Jayarajan P & Mahor A (2020). Reinforcement learning concepts ministering smart city applications using iot. *Internet of Things in Smart Technologies for Sustainable Urban Development*, 19-41.
- Dinç Y (2019). Lojistik sektöründe büyük veri kullanımı: Mersin ili örneği (Master's thesis).
- Dong M (2006). *Development of supply chain network robustness index*. *International Journal of Services Operations and Informatics*, 1(1-2), 54-66.
- Dong XL & Srivastava D (2013). *Big data integration*. In 2013 IEEE 29th international conference on data engineering (ICDE) (pp. 1245-1248). IEEE.
- Dongare AD, Kharde RR & Kachare AD (2012). Introduction to artificial neural network. *International Journal of Engineering and Innovative Technology (IJEIT)*, 2(1), 189-194.
- Draper BA, Baek K & Boody J (2003). Implementing the expert object recognition pathway. In *Computer Vision Systems: Third International Conference, ICVS*

- 2003, Graz, Austria, April 1–3, 2003. Proceedings 3 (pp. 1-11). Springer Berlin Heidelberg.
- Dreischmeier R, Close K & Trichet P (2015). *The digital imperative*. BCG Perspectives.
- Drucker P F (1998). *Management's new paradigms*. Forbes magazine, 10(2), 98-99.
- Eaton D, Deroos T, Deutsch G, Lapis & Zikopoulos PC (2012). Understanding Big Data: Analytics for Enterprise Class Hadoop and Streaming Data, *Mc Graw-Hill Companies*.
- Ebner K, Bühnen T & Urbach N (2014). *Think big with big data: Identifying suitable big data strategies in corporate environments*. In 2014 47th Hawaii International conference on system sciences (pp. 3748-3757). IEEE.
- Einav L & Levin J (2014). Economics in the age of big data. Science, 346(6210), 1243089.
- Elliott DL (1993). *A better activation function for artificial neural networks*.
- Elmas Ç (2003). *Yapay Sinir Ağları*, Seçkin Yayınevi, Ankara.
- Erdal H & Yapraklı TS (2016). Firm failure prediction: A case study based on machine learning. *International Journal of Informatics Technologies*, 9(1), 21-31.
- Erol İ, Nurtanış Velioğlu M & Sivrikaya Şerifoğlu F (2006). *AB uyum yasaları ve sürdürülebilir kalkınma bağlamında tersine tedarik zinciri yönetimi: Türkiye'ye yönelik araştırma fırsatları ve önerileri*. İktisat İşletme ve Finans, 21 (44): 86–106.
- Eskandarpour M, Dejax P, Miemczyk J & Péton O (2015). Sustainable supply chain network design: An optimization-oriented review. *Omega*, 54, 11-32.
- Eymen, U. E. (2007). Tedarik zinciri yönetimi. *Kalite Ofisi Yayınları*, 15.
- Fan J, Han F & Liu H (2014). Challenges of big data analysis. *National science review*, 1(2), 293-314.
- Fawcett SE & Magnan GM (2002). The rhetoric and reality of supply chain integration. *International Journal of Physical Distribution & Logistics Management*, 32(5), 339-361.
- Fawcett SE, Magnan GM & McCarter MW (2008). Benefits, barriers, and bridges to effective supply chain management. *Supply chain management: An international journal*.

- Fawcett T (2006). An introduction to ROC analysis. *Pattern recognition letters*, 27(8), 861-874.
- Feizabadi J (2022). Machine learning demand forecasting and supply chain performance. *International Journal of Logistics Research and Applications*, 25(2), 119-142.
- Fernie J (1999). Quick Response in retail distribution: An international perspective. *Quick Response in the Supply Chain*, 173-187.
- Fischer C, Pardos ZA, Baker RS, Williams JJ, Smyth P, Yu R, ... & Warschauer M (2020). Mining big data in education: Affordances and challenges. Review of Research in Education, 44(1), 130-160.
- Forrester JW (1958). Industrial Dynamics: A Major Breakthrough for Decision Makers, *Harvard Business Review*, vol. 36, no. 4, pp. 37-66.
- Forrester JW (1997). Industrial dynamics. *Journal of the Operational Research Society*, 48(10), 1037-1041.
- Fox C (2018). Bayesian inference. *Data Science for Transport: A Self-Study Guide with Computer Exercises*, 75-92.
- Fox MS, Chionglo JF & Barbuceanu M (1993). *The integrated supply chain management system*. Technical report, Department of Industrial Engineering, University of Toronto.
- Frazzon EM, Rodriguez CMT, Pereira MM, Pires MC & Uhlmann I. (2019) Towards supply chain management 4.0. *Brazilian Journal of Operations & Production Management*, 16(2), 180-191.
- Galitsky B (2022). Obtaining supported decision trees from text for health system applications. *Artificial Intelligence for Healthcare Applications and Management*, 71.
- Gantz J & Reinsel D (2012). The digital universe in 2020: Big data, bigger digital shadows, and biggest growth in the far east. *IDC iView: IDC Analyze the future*, 2007(2012), 1-16.
- Gao RX, Wang L, Helu M & Teti R (2020). Big data analytics for smart factories of the future. *CIRP annals*, 69(2), 668-692.
- Geisler S, Zügner D & Günnemann S (2020). Reliable graph neural networks via robust aggregation. *Advances in Neural Information Processing Systems*, 33, 13272-13284.

- George G, Haas MR & Pentland A (2014). *Big data and management*. Academy of management Journal, 57(2), 321-326.
- Ghemawat S, Gobioff H & Leung ST (2003). The Google file system. *In Proceedings of the nineteenth ACM symposium on Operating systems principles* (pp. 29-43).
- Gispan L, Leshem A & Be'ery Y (2017). Decentralized estimation of regression coefficients in sensor networks. *Digital Signal Processing*, 68, 16-23.
- Görçün ÖF (2010). *Tedarik zinciri yönetimi*. İstanbul, Beta Yayın Evi.
- Graupe D (2019). *Principles of artificial neural networks: basic designs to deep learning*.
- Gripsrud G, Jahre M & Persson G (2006). Supply chain management—back to the future?. *International Journal of Physical Distribution & Logistics Management*.
- Grzymala-Busse JW & Stefanowski J (2001). Three discretization methods for rule induction. *International Journal of Intelligent Systems*, 16(1), 29-38.
- Guide VDR (2000). Production planning and control for remanufacturing: industry practice and research needs. *Journal of operations Management*, 18(4), 467-483.
- Guide VDR, Harrison TP & Van Wassenhove LN (2003). *The challenge of closed-loop supply chains*. *Interfaces*, 33(6), 3-6.
- Gunasekaran A, Hong P & Fujimoto T. (2014). *Building supply chain system capabilities in the age of global complexity: Emerging theories and practices*. *International journal of production economics*, 147(PART B), 189-197.
- Guo G, Li SZ & Chan K (2000). Face recognition by support vector machines. *In Proceedings fourth IEEE international conference on automatic face and gesture recognition* (cat. no. PR00580) (pp. 196-201). IEEE.
- Gupta N (2013). Artificial neural network. *Network and Complex Systems*, 3(1), 24-28.
- Gupta A, Baid P & Chaplot N (2017). Sentiment analysis of movie reviews using machine learning techniques. *International Journal of Computer Applications*, 179(7), 45-49.
- Gupta UG & Gupta A (2016). Vision: a missing key dimension in the 5V Big Data framework. *Journal of International Business Research and Marketing*, 1(3), 50-56.
- Gültepe Y (2019). Makine öğrenmesi algoritmaları ile hava kirliliği tahmini üzerine karşılaştırmalı bir değerlendirme. *Avrupa Bilim ve Teknoloji Dergisi*, (16), 8-15.

- Habib MM & Jungthirapanich C (2008). An integrated framework for research and education supply chain for the universities. In 2008 4th IEEE International Conference on Management of Innovation and Technology (pp. 1027-1032). IEEE.
- Habib M (2009). An integrated educational supply chain management (ITESCM). *Graduate School of Information Technology*.
- Habib M (2014). Supply chain management (SCM): Its future implications. *Open Journal of Social Sciences*, 2(09), 238.
- Hady MFA & Schwenker F (2013). Semi-supervised learning. *Handbook on Neural Information Processing*, 215-239.
- Halldorsson A, Kotzab H, Mikkola JH & Skjøtt-Larsen T (2007). *Complementary theories to supply chain management*. Supply chain management: An international journal, 12(4), 284-296.
- Han J, Mao K, Xu T, Guo J, Zuo Z & Gao C (2018). A soil moisture estimation framework based on the CART algorithm and its application in China. *Journal of hydrology*, 563, 65-75.
- Handfield RB & Nicholas EL (1999). *Introduction to Supply Chain Management*, Prentice-Hall, Inc., New Jersey.
- Harjeet S, Jaggi Mr & Sunny SK (2016). Integration of Spark framework in Supply Chain Management, *Procedia Computer Science*.
- Harper RL (2010). *Warehouse technology in the supply chain management systems*. In 2010 Proceedings-Annual Reliability and Maintainability Symposium (RAMS) (pp. 1-5). IEEE.
- Hashem IAT, Yaqoob I, Anuar NB., Mokhtar S, Gani A & Khan SU (2015). The rise of “big data” on cloud computing: Review and open research issues. *Information systems*, 47, 98-115.
- Hastie T, Tibshirani R, Friedman J, Hastie T, Tibshirani R & Friedman J (2009). Support vector machines and flexible discriminants. *The elements of statistical learning: data mining, inference, and prediction*, 417-458.
- Hattori K & Takahashi M (1999). A new nearest-neighbor rule in the pattern classification problem. *Pattern recognition*, 32(3), 425-432.
- Hearst MA (1998). Automated discovery of WordNet relations. *WordNet: an electronic lexical database*, 2.

- Hearst MA, Dumais ST, Osuna E, Platt J & Scholkopf B (1998). Support vector machines. *IEEE Intelligent Systems and their applications*, 13(4), 18-28.
- Heller KA & Ghahramani Z (2005). Bayesian hierarchical clustering. *In Proceedings of the 22nd international conference on Machine learning* (pp. 297-304).
- Helm JM, Swiergosz AM, Haeberle HS, Karnuta JM, Schaffer JL, Krebs VE, ... & Ramkumar PN (2020). Machine learning and artificial intelligence: definitions, applications, and future directions. *Current reviews in musculoskeletal medicine*, 13, 69-76.
- Hinton, 2013
- Hendler J (2008). Why Do We Need Intelligent Systems?. *IEEE Intelligent Systems*, 23(06), 2-3.
- Hendricks KB & Singhal VR (2003). *The effect of supply chain glitches on shareholder wealth*. *Journal of operations Management*, 21(5), 501-522.
- Hendry C, Jones A & Arthur M (1991). Skill supply, training and development in the small-medium enterprise. *International Small Business Journal*, 10(1), 68-72.
- Heskett JL, Glaskowsky NA & Ivie RM (1973). *Business logistics: Physical distribution and materials management* (Vol. 1). New York: Ronald Press Company.
- Hinton GE (1992). How neural networks learn from experience. *Scientific American*, 267(3), 144-151.
- Hinton GE, Srivastava N, Krizhevsky A, Sutskever I & Salakhutdinov RR (2012). *Improving neural networks by preventing co-adaptation of feature detectors*. Technical Report arXiv:1207.0580.
- Hobbs JE (1996). A transaction cost approach to supply chain management. *Supply Chain Management: An International Journal*, 1(2), 15-27.
- Hodge V & Austin J (2004). A survey of outlier detection methodologies. *Artificial intelligence review*, 22, 85-126.
- Hofmann E & Rüsç M (2017). *Industry 4.0 and the current status as well as future prospects on logistics*. *Computers in industry*, 89, 23-34.
- Hollmann D (2011). Supply Chain network design under uncertainty and risk (Doctoral dissertation, Brunel University, School of Information Systems, Computing and Mathematics).

- Holten R, Dreiling A, Muehlen M & Becker J (2002). *Enabling technologies for supply chain process management*. In Information Resource Management Association International Conference, Seattle, Washington.
- Hoppe MT (2019). Machine learning in supply chain management (Doctoral dissertation).
- Hu H, Xu J, Liu M & Lim MK (2023). Vaccine supply chain management: An intelligent system utilizing blockchain, IoT and machine learning. *Journal of business research*, 156, 113480.
- Huang SH & Zhang HC (1994). Artificial neural networks in manufacturing: concepts, applications, and perspectives. *IEEE Transactions on Components, Packaging, and Manufacturing Technology: Part A*, 17(2), 212-228.
- Hugos MH (2002). *Essentials of supply chain management*. John Wiley & Sons.
- Hult GTM, Craighead CW & Ketchen Jr DJ (2010). Risk uncertainty and supply chain decisions: a real options perspective. *Decision Sciences*, 41(3), 435-458.
- Hung CC & Hsieh CC (2017). Big data management on wireless sensor networks. In *big data analytics for sensor-network collected intelligence* (pp. 99-116). Academic Press.
- Hunter NA & Valentino P (1995). Quick response—ten years later. *International Journal of Clothing Science and Technology*, 7(4), 30-40.
- Inukollu VN, Arsi S & Ravuri SR (2014). Security issues associated with big data in cloud computing. *International Journal of Network Security & Its Applications*, 6(3), 45.
- Ip A, Fong S & Liu E (2010). Optimization for allocating BEV recharging stations in urban areas by using hierarchical clustering. In *2010 6th International conference on advanced information management and service (IMS)* (pp. 460-465). IEEE.
- Ivosev G, Burton L & Bonner R (2008). Dimensionality reduction and visualization in principal component analysis. *Analytical chemistry*, 80(13), 4933-4944.
- Jabbar MA, Samreen S & Aluvalu R (2018). The future of health care: Machine learning. *International Journal of Engineering & Technology*, 7(4.6), 23-25.
- Jadhav SD & Channe HP (2016). Comparative study of K-NN, naive Bayes and decision tree classification techniques. *International Journal of Science and Research (IJSR)*, 5(1), 1842-1845.

- Jagadish HV, Gehrke J, Labrinidis A, Papakonstantinou Y, Patel JM, Ramakrishnan R & Shahabi C (2014). Big data and its technical challenges. *Communications of the ACM*, 57(7), 86-94.
- Jain AK, Mao J & Mohiuddin KM (1996). Artificial neural networks: A tutorial. *Computer*, 29(3), 31-44.
- Jang SJ, Han CH, Lee KE & Yoo SJ (2019). Reinforcement learning-based dynamic band and channel selection in cognitive radio ad-hoc networks. *EURASIP Journal on Wireless Communications and Networking*, 2019, 1-25.
- Jayaraman V & Ross A (2003). A simulated annealing methodology to distribution network design and management. *European Journal of Operational Research*, 144(3), 629-645.
- Jayaseelan R, Mitra T & Li X (2006). Estimating the worst-case energy consumption of embedded software. In *12th IEEE Real-Time and Embedded Technology and Applications Symposium (RTAS'06)* (pp. 81-90). IEEE.
- Jiang J, Gan S, Liu Y, Wang F, Alonso G, Klimovic A, ... & Zhang C (2021). Towards demystifying serverless machine learning training. In *Proceedings of the 2021 International Conference on Management of Data* (pp. 857-871).
- Jiang W, Li L, Li X, Moser KL, Guo Z, Du L, ... & Rao S (2005). A robust hybrid between genetic algorithm and support vector machine for extracting an optimal feature gene subset. *Genomics*, 85(1), 16-23.
- Jin X, Wah BW, Cheng X, & Wang Y (2015). Significance and challenges of big data research. *Big data research*, 2(2), 59-64.
- Jüttner U, Christopher M & Baker S (2007). *Demand chain management-integrating marketing and supply chain management*. *Industrial marketing management*, 36(3), 377-392.
- Kalaycı Ş (2009). *Basit Doğrusal Regresyon. SPSS uygulamalı Çok Değişkenli İstatistik Teknikleri*, Der. Kalaycı Ş, 199-203.
- Kaliraj P & Devi T (2022). *Big Data Applications in Industry 4.0*. CRC Press.
- Kanungo T, Mount DM, Netanyahu NS, Piatko CD, Silverman R & Wu AY (2002). An efficient k-means clustering algorithm: Analysis and implementation. *IEEE transactions on pattern analysis and machine intelligence*, 24(7), 881-892.
- Karaboğa T & Zehir C (2020). *Büyük Verinin Etkin Yönetiminde Stratejik Uyum ve Veri Odaklı Kültür*. *IBAD Sosyal Bilimler Dergisi*, (8), 63-76.

- Karakoyun HM & Hacibeyođlu M (2014). Statistical comparison of machine learning classification algorithms using biomedical data sets. *Dokuz Eylul Univ Fac Eng J Sci Eng*, 16, 30-41.
- Katal A, Wazid M & Goudar RH (2013). Big data: issues, challenges, tools and good practices. *In 2013 Sixth international conference on contemporary computing (IC3)* (pp. 404-409). IEEE.
- Kaur P, Sharma M & Mittal M (2018). Big data and machine learning based secure healthcare framework. *Procedia computer science*, 132, 1049-1059.
- Kavakiotis I, Tsave O, Salifoglou A, Maglaveras N, Vlahavas I & Chouvarda I (2017). Machine learning and data mining methods in diabetes research. *Computational and structural biotechnology journal*, 15, 104-116.
- Kaya Ç & Yildiz O (2014). Makine öğrenmesi teknikleriyle saldırı tespiti: Karşılaştırmalı analiz. *Marmara University Journal of Science*, 26(3).
- Kaya A & Alumur AS (2017). Kapalı Döngü Tedarik Zinciri Ađı Tasarımı. *Endüstri Mühendisliđi Dergisi*, 28(2):2-18.
- Kaynar O, Görmez Y, Yıldız M & Albayrak A (2016). Makine öğrenmesi yöntemleri ile Duygu Analizi. *In International Artificial Intelligence and Data Processing Symposium (IDAP'16)* (Vol. 17, No. 18, pp. 17-18).
- Kaynar O, Yüksek AG, Görmez Y & Işık YE (2017). Intrusion detection with autoencoder based deep learning machine. *In 2017 25th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- Kehoe D & Boughton N (2001). *Internet based supply chain management: A classification of approaches to manufacturing planning and control*. International Journal of Operations & Production Management.
- Khan M, Wu X, Xu X & Dou W (2017). *Big data challenges and opportunities in the hype of Industry 4.0*. In 2017 IEEE International Conference on Communications (ICC) (pp. 1-6). IEEE.
- Khan R, Ali J, Ahmad N & Maqsood I (2012). Random forests and decision trees. *International Journal of Computer Science Issues (IJCSI)*, 9(5), 272. Khanna vd., 2016
- Khoo LP & Yin XF (2003). *An extended graph-based virtual clustering-enhanced approach to supply chain optimisation*. The International Journal of Advanced Manufacturing Technology, 22, 836-847.

- Kim J & Yang I (2020). Hamilton-Jacobi-Bellman equations for q-learning in continuous time. *In Learning for Dynamics and Control* (pp. 739-748). PMLR.
- Kiran BR, Sobh I, Talpaert V, Mannion P, Al Sallab AA, Yogamani S & Pérez P (2021). Deep reinforcement learning for autonomous driving: A survey. *IEEE Transactions on Intelligent Transportation Systems*, 23(6), 4909-4926.
- Kiraz MU & Yilmaz A (2022). Comparison of ml algorithms to detect vulnerabilities of rpl-based iot devices in intelligent and fuzzy systems. *In Intelligent and Fuzzy Techniques for Emerging Conditions and Digital Transformation: Proceedings of the INFUS 2021 Conference*, held August 24-26, 2021. Volume 2 (pp. 254-262). Springer International Publishing.
- Kitchens B, David D, Jingjing L & Ahmed A (2018). Advanced Customer Analytics: Strategic Value Through Integration of Relationship Oriented Big Data. *Journal of Management Information Systems*. c.35. s.2: 540-574.
- Kleab K (2017). *Important of supply chain management*. *International Journal of Scientific and Research Publications*, 7(9), 397-400.
- Klibi W, Martel A & Guitouni A (2010). *The design of robust value-creating supply chain networks: a critical review*. *European Journal of Operational Research*, 203(2), 283-293.
- Kobu B (2010). Üretim Yönetimi. *Beta Yayınları*, İstanbul.
- Koch G, Zemel R & Salakhutdinov R (2015). Siamese neural networks for one-shot image recognition. *In ICML deep learning workshop* (Vol. 2, No. 1).
- Koç M, Balas C & Arslan A (2004). Preliminary design of rubble mound breakwaters by using artificial neural networks. *Technical Journal of Turkish Chamber of Civil Engineers*, 15(4).
- Koç, Y. (2016). Hayvancılıkta elde edilen farklı verilere regresyon ağacı metodunun uygulanması (Master's thesis, Fen Bilimleri Enstitüsü).
- Kotsiantis SB, Zaharakis I & Pintelas P (2007). Supervised machine learning: A review of classification techniques. *Emerging artificial intelligence applications in computer engineering*, 160(1), 3-24.
- Koseleva N & Ropaite G (2017). Big data in building energy efficiency: understanding of big data and main challenges. *Procedia Engineering*, 172, 544-549.

- Kothari SS, Jain SV & Venkateshwar A (2018). The impact of IOT in supply chain management. *International Research Journal of Engineering and Technology*, 5(8), 257-259.
- Krikke H, Blanc IL & van de Velde S (2004). Product modularity and the design of closed-loop supply chains. *California management review*, 46(2), 23-39.
- Krogh A (2008). What are artificial neural networks?. *Nature biotechnology*, 26(2), 195-197.
- Kruse R, Mostaghim S, Borgelt C, Braune C & Steinbrecher M (2022). Neural Networks: Mathematical Remarks. In *Computational Intelligence: A Methodological Introduction* (pp. 213-221). Cham: Springer International Publishing.
- Kulkarni VY & Sinha PK (2012). Pruning of random forest classifiers: A survey and future directions. In *2012 International Conference on Data Science & Engineering (ICDSE)* (pp. 64-68). IEEE.
- Kumar B, Vyas OP & Vyas R (2019). A comprehensive review on the variants of support vector machines. *Modern Physics Letters B*, 33(25), 1950303.
- Kumar DP, Amgoth T & Annavarapu CSR (2019). Machine learning algorithms for wireless sensor networks: A survey. *Information Fusion*, 49, 1-25.
- Kumar M, Raghuwanshi NS, Singh R, Wallender WW & Pruitt WO (2002). Estimating evapotranspiration using artificial neural network. *Journal of Irrigation and Drainage Engineering*, 128(4), 224-233.
- Kung,L, Kung HJ, Jones-Farmer A & Wang Y (2015). Managing big data for firm performance: a configurational approach.
- Kuo CCJ (2016). Understanding convolutional neural networks with a mathematical model. *Journal of Visual Communication and Image Representation*, 41, 406-413.
- Kwon O, Lee N & Shin B (2014). Data quality management, data usage experience and acquisition intention of big data analytics. *International journal of information management*, 34(3), 387-394.
- La Londe BJ & James MM. (1994). Emerging Logistics Strategies: Blueprintsfor the Next Century. *International Journal of Physical Distribution and Logistics Management*, Vol. 24, No. 7, pp. 35-47.
- La Londe BJ (1997). Supply Chain Management: Myth or Reality?. *Supply Chain Management Review*, Vol. 1, Spring, pp. 6-7.

- Lalwani CS, Disney SM & Naim MM (2006). *On assessing the sensitivity to uncertainty in distribution network design*. International Journal of Physical Distribution & Logistics Management.
- Lamba HS & Dubey SK (2015). Analysis of requirements for big data adoption to maximize IT business value. *In 2015 4th International Conference on Reliability, Infocom Technologies and Optimization (ICRITO)(Trends and Future Directions)* (pp. 1-6). IEEE.
- Lambert DM, Cooper MC & Pagh JD. (1998). Supply chain management: implementation issues and research opportunities. *The international journal of logistics management*, 9(2), 1-20.
- Lambert DM & Cooper MC (2000). Issues in supply chain management. *Industrial marketing management*, 29(1), 65-83.
- Lambert DM & Stock JR (1993). *Strategic logistics management* (Vol. 69). Homewood, IL: Irwin.
- Laney D (2001). 3D data management: Controlling data volume, velocity and variety. *META group research note*, 6(70), 1.
- Langley P (2016). Explainable agency in human-robot interaction. *In AAAI fall symposium series*.
- Larson PD & Rogers DS (1998). Supply chain management: definition, growth and approaches. *Journal of Marketing Theory and Practice*, 6(4), 1-5.
- Lazer D, Kennedy R, King G & Vespignani A (2014). The parable of Google Flu: traps in big data analysis. *science*, 343(6176), 1203-1205.
- LeCun Y, Bengio Y & Hinton G (2015). Deep learning. *nature*, 521(7553), 436-444.
- Lee CC, Mower E, Busso C, Lee S & Narayanan S (2011). Emotion recognition using a hierarchical binary decision tree approach. *Speech Communication*, 53(9-10), 1162-1171.
- Lee Y & Kincade DH (2003). *US apparel manufacturers' company characteristic differences based on SCM activities*. Journal of Fashion Marketing and Management: An International Journal.
- Lei Y, Qiaoming H & Tong Z (2023). Research on Supply Chain Financial Risk Prevention Based on Machine Learning. *Computational Intelligence and Neuroscience*, 2023.

- Lek S & Guégan JF (1999). Artificial neural networks as a tool in ecological modelling, an introduction. *Ecological modelling*, 120(2-3), 65-73.
- Lemoine OW & Skjoett-Larsen T (2004). *Reconfiguration of supply chains and implications for transport: a Danish study*. International Journal of Physical Distribution & Logistics Management.
- Li Y & Han Y (2017). Decline curve analysis for production forecasting based on machine learning. In *SPE Symposium: Production Enhancement and Cost Optimisation*. OnePetro.
- Liu P, Yuan W, Fu J, Jiang Z, Hayashi H & Neubig G (2023). Pre-train, prompt, and predict: A systematic survey of prompting methods in natural language processing. *ACM Computing Surveys*, 55(9), 1-35.
- Lorena AC & De Carvalho AC (2009). Evaluation functions for the evolutionary design of multiclass support vector machines. *International Journal of Computational Intelligence and Applications*, 8(01), 53-68.
- Lu HE, Potter A, Sanchez Rodrigues V & Walker H (2018). Exploring sustainable supply chain management: a social network perspective. *Supply Chain Management: An International Journal*, 23(4), 257-277.
- Lucey S & Ashraf AB (2013). Nearest neighbor classifier generalization through spatially constrained filters. *Pattern recognition*, 46(1), 325-331.
- Lummus RR & Vokurka RJ (1999). *Defining supply chain management: a historical perspective and practical guidelines*. Industrial management & data systems.
- Lundin D, Poole M, Sjöberg BM & Högbom M (2012). *Use of structural phylogenetic networks for classification of the ferritin-like superfamily*. Journal of Biological Chemistry, 287(24), 20565-20575.
- Luo W, Li Y, Urtasun R & Zemel R (2016). Understanding the effective receptive field in deep convolutional neural networks. *Advances in neural information processing systems*, 29.
- Luthra S & Mangla SK (2018). *Evaluating challenges to Industry 4.0 initiatives for supply chain sustainability in emerging economies*. Process Safety and Environmental Protection, 117, 168-179.
- Ma S & Dai Y (2011). Principal component analysis based methods in bioinformatics studies. *Briefings in bioinformatics*, 12(6), 714-722.

- Machado F, Mine M, Kaviski E & Fill H (2011). Monthly rainfall–runoff modelling using artificial neural networks. *Hydrological Sciences Journal–Journal des Sciences Hydrologiques*, 56(3), 349-361.
- Machlev R, Tolkachov D, Levron Y & Beck Y (2020). Dimension reduction for NILM classification based on principle component analysis. *Electric Power Systems Research*, 187, 106459.
- Mahesh B (2020). Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*. 9, 381-386.
- Makkar S, Devi GNR & Solanki VK (2020). Applications of machine learning techniques in supply chain optimization. In *ICICCT 2019–System Reliability, Quality Control, Safety, Maintenance and Management: Applications to Electrical, Electronics and Computer Science and Engineering* (pp. 861-869). Springer Singapore.
- Manovich L (2011). Trending: The promises and the challenges of big social data. *Debates in the digital humanities*, 2(1), 460-475.
- Manson-Jones NB & Towill D (2000). *Engineering the Leagile Supply Chain International*. *Journal of Agile Management Systems*, 2(1), 54-61.
- Marblestone AH, Wayne G & Kording KP (2016). Toward an integration of deep learning and neuroscience. *Frontiers in computational neuroscience*, 94.
- Marr B (2016) What is the Difference Between Artificial Intelligence and Machine Learning?, *Forbes*.
- Marshall RJ (2001). The use of classification and regression trees in clinical epidemiology. *Journal of clinical epidemiology*, 54(6), 603-609.
- McAfee A, Brynjolfsson E, Davenport TH, Patil DJ & Barton D (2012). *Big data: the management revolution*. *Harvard business review*, 90(10), 60-68.
- McCarthy J, Minsky ML, Rochester N & Shannon CE (2006). A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. *AI magazine*, 27(4), 12-12.
- McCulloch WS & Pitts W (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5, 115-133.
- McKinsey Global Institute: Manyika J, Chui M, Brown B, Bughin J, Dobbs R, Roxburgh C & Hung Byers A (2011). Big data: The next frontier for innovation, competition, and productivity.

- McIvor R & Humphreys P (2004). *Early supplier involvement in the design process: lessons from the electronics industry*. *Omega*, 32(3), 179-199.
- Mehrotra K, Mohan CK & Ranka S (1997). *Elements of artificial neural networks*. MIT press.
- Melo T, Nickel S & Gama F (2007). *Facility location and supply chain management—a comprehensive review*.
- Melo MT, Nickel S & Saldanha-Da-Gama F (2009). *Facility location and supply chain management—A review*. *European journal of operational research*, 196(2), 401-412.
- Mentzer JT, DeWitt W, Keebler JS, Min S, Nix NW, Smith CD & Zacharia ZG. (2001). Defining supply chain management. *Journal of Business logistics*, 22(2), 1-25.
- Mentzer JT & Moon MA (2004). *Sales forecasting management: a demand management approach*. Sage Publications.
- Mijwel MM (2018). Artificial neural networks advantages and disadvantages. Retrieved from *LinkedIn* <https://www.linkedin.com/pulse/artificial-neuralnet-Work>.
- Min H & Zhou G (2002). *Supply chain modeling: past, present and future*. *Computers & industrial engineering*, 43(1-2), 231-249.
- Misra S & He J (2019). *Machine learning for subsurface characterization*. Gulf Professional Publishing.
- Mitchell TM (1997). *Machine* (Vol. 1, No. 9). New York: McGraw-hill.
- Mitchell TM (1999). Machine learning and data mining. *Communications of the ACM*, 42(11), 30-36.
- Miyazaki H, Kamei M, Shigesato Y & Yasui I (1999). *Influence of unbalanced magnetron and penning ionization for RF reactive magnetron sputtering*. *Japanese journal of applied physics*, 38(1R), 186.
- Mojarad M, Nejatian S, Parvin H & Mohammadpoor M (2019). A fuzzy clustering ensemble based on cluster clustering and iterative Fusion of base clusters. *Applied Intelligence*, 49, 2567-2581.
- Monczka RM & Morgan J (1997). What's wrong with supply chain management. *Purchasing*, 122(1), 69-73.

- Moor JH (2006). The nature, importance, and difficulty of machine ethics. *IEEE intelligent systems*, 21(4), 18-21.
- Morabito V (2015). *Big data and analytics*. Strategic and organisational impacts.
- Mowat A & Collins R (2000). *Consumer behaviour and fruit quality: supply chain management in an emerging industry*. *Supply Chain Management: An International Journal*, 5(1), 45-54.
- Mulvey JM, Vanderbei RJ & Zenios SA (1995). *Robust optimization of large-scale systems*. *Operations research*, 43(2), 264-281.
- Murat GÖK (2017). Makine öğrenmesi yöntemleri ile akademik başarının tahmin edilmesi. *Gazi University Journal of Science Part C: Design and Technology*, 5(3), 139-148.
- Myers RH, Montgomery DC, Vining GG & Robinson TJ (2012). *Generalized linear models: with applications in engineering and the sciences*. John Wiley & Sons.
- Nacar EN & Erdebilli B (2021). Makine Öğrenmesi Algoritmaları İle Satış Tahmini. *Endüstri Mühendisliği*, 32(2), 307-320.
- Nagar J, Singh A, Kotiyal V, Sharma S & Lee CC (2020). A machine learning approach to predict the average localization error with applications to wireless sensor networks. *IEEE Access*, 8, 208253-208263.
- Narasimhan R & Narayanan S (2013). *Perspectives on supply network-enabled innovations*. *Journal of Supply Chain Management*, 49(4), 27-42.
- Nasteski V (2017). *An overview of the supervised machine learning methods*. *Horizons*. b, 4, 51-62.
- Ni P, Huang N, Zhang Z, Wang DP, Liang F, Miao Y, ... & Wang J (2019). DeepSignal: detecting DNA methylation state from Nanopore sequencing reads using deep-learning. *Bioinformatics*, 35(22), 4586-4595.
- Nilsson NJ (1996). *Introduction to machine learning*.
- Nikbakhsh E (2009). *Green supply chain management*. *Supply Chain and Logistics in National, International and Governmental Environment: Concepts and Models*, 195-220.
- Oh J & Jeong B (2019). *Tactical supply planning in smart manufacturing supply chain*. *Robotics and Computer-Integrated Manufacturing*, 55, 217-233.
- Ohno T (1998). *The Toyota production system: beyond large scale production*. Productivity Press, Cambridge. 143 p.

- Oliver RK & Webber MD (1992). Supply chain management: Logistic catches up with strategy. 1982. *Outlook cit. Christopher, M., Logistics, the Strategic Issues*.
- Olson DL, Delen D & Meng Y (2012). Comparative analysis of data mining methods for bankruptcy prediction. *Decision Support Systems*, 52(2), 464-473.
- Onay A (2020). Büyük Veri Çağında İç Denetimin Dönüşümü. *Muhasebe Bilim Dünyası Dergisi*, 22(1), 127-163.
- Özal ÖM (2011). Yalın Tedarik Zinciri Yönetimi ve İmalat Sektöründe Tedarikçi Seçim Uygulaması, Yüksek Lisans Tezi, Hava Harp Okulu Havacılık ve Uzay Teknolojileri Enstitüsü, İstanbul.
- Özari İM & Arslan A (2018). *Dijital Sanayi Devriminin Lojistik Sektörüne Getireceği Yenilikler ve Etkileri*, 7. Ulusal Lojistik ve Tedarik Zinciri Kongresi, ULTZK, 3-5.
- Özdemir Aİ (2004). Tedarik zinciri yönetiminin gelişimi, süreçleri ve yararları. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (23).
- Öztaş K & Uçan H (2002). *Turizm sektöründe mutfak hizmetleri*, Nobel Yayın Dağıtım, Ankara.
- Öztemel E (2006). *Yapay sinir ağları*. Papatya Yayıncılık.
- Öztürk K & Şahin ME (2018). A general view of artificial neural networks and artificial intelligence. *Takvim-i Vekayi*, 6(2), 25-36.
- Paksoy T (2005). *Tedarik Zinciri Yönetiminde Dağıtım Ağlarının Tasarımı Ve Optimizasyonu: Malzeme İhtiyaç Kısıtı Altında Stratejik Bir Üretim-Dağıtım Modeli*. Selçuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, (14), 435-454.
- Paksoy T, Gunduz MA & Demir S. (2021). Matching functions of supply chain management with smart and sustainable Tools: A novel hybrid BWM-QFD based method. *Computers & Industrial Engineering*, 162, 107676.
- Pence HE (2014). Will Big Data Mean the End of Privacy?. *Journal of educational technology systems*, 44(2), 253-267.
- Peterson LE (2009). K-nearest neighbor. *Scholarpedia*, 4(2), 1883.
- Power D (2005). *Supply chain management integration and implementation: a literature review*. Supply chain management: an International journal, 10(4), 252-263.
- Pradhan A (2012). Support vector machine-a survey. *International Journal of Emerging Technology and Advanced Engineering*, 2(8), 82-85.

- Pujianto U, Wibawa AP & Akbar MI (2019). K-nearest neighbor (k-NN) based missing data imputation. *In 2019 5th International Conference on Science in Information Technology (ICSITech)* (pp. 83-88). IEEE.
- Puttagunta M & Ravi S (2021). Medical image analysis based on deep learning approach. *Multimedia tools and applications*, 80, 24365-24398.
- Quinlan JR (1986). Induction of decision trees. *Machine learning*, 1, 81-106.
- Qu Y, Quan P, Lei M & Shi Y (2019). Review of bankruptcy prediction using machine learning and deep learning techniques. *Procedia Computer Science*, 162, 895-899.
- Radivojević G & Milosavljević L (2019). The concept of logistics 4.0. *In 4th Logistics International Conference* (pp. 23-25).
- Raj A, Dwivedi G, Sharm, A, de Sousa Jabbour ABL & Rajak S (2020). *Barriers to the adoption of industry 4.0 technologies in the manufacturing sector: An inter-country comparative perspective*. *International Journal of Production Economics*, 224, 107546.
- Rodrigue JP (2020). *The geography of transport systems*. Routledge.
- Rogers DS & Tibben-Lembke R (2001). *An examination of reverse logistics practices*. *Journal of business logistics*, 22(2), 129-148.
- Rokach L & Maimon O (2005). Top-down induction of decision trees classifiers-a survey. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 35(4), 476-487.
- Rosipal R & Krämer N (2006). Overview and recent advances in partial least squares. *In Subspace, Latent Structure and Feature Selection: Statistical and Optimization Perspectives Workshop, SLSFS 2005*, Bohinj, Slovenia, February 23-25, 2005, Revised Selected Papers (pp. 34-51). Springer Berlin Heidelberg.
- Ross DF (1997). *Competing through supply chain management: creating market-winning strategies through supply chain partnerships*. Springer Science & Business Media.
- Ross DF (1998). *Meeting the challenge of supply chain management*. In *Competing Through Supply Chain Management: Creating Market-Winning Strategies Through Supply Chain Partnerships* (pp. 1-35). Boston, MA: Springer US.
- Rusko RT, Kylänen M & Saari R (2009). *Supply chain in tourism destinations: the case of Levi Resort in Finnish Lapland*. *International Journal of Tourism Research*, 11(1), 71-87.

- Russom P (2011). Big data analytics. *TDWI best practices report, fourth quarter*, 19(4), 1-34.
- Sabri EH & Beamon BM (2000). A multi-objective approach to simultaneous strategic and operational planning in supply chain design. *Omega*, 28(5), 581-598.
- Sagioglu S & Sinanc D (2013). *Big data: A review*. In *2013 international conference on collaboration technologies and systems (CTS)* (pp. 42-47). IEEE.
- Samuel AL (1959). Some studies in machine learning using the game of checkers. *IBM Journal of research and development*, 3(3), 210-229.
- Sari R (2020). Analisis sentimen pada review objek wisata dunia fantasi menggunakan algoritma K-Nearest Neighbor (k-nn). *EVOLUSI: Jurnal Sains Dan Manajemen*, 8(1).
- Say, C. (2018). *50 Soruda yapay zekâ*. Bilim ve Gelecek Kitaplığı.
- Scmdojo (2023) Evolution of Supply Chain Management and Logistics <https://www.scmdojo.com/history-and-evolution-of-supply-chain-and-logistics/>
- Schmidt G & Wilhelm WE. (2000). *Strategic, tactical and operational decisions in multi-national logistics networks: a review and discussion of modelling issues*. *International Journal of Production Research*, 38(7), 1501-1523.
- Schneider R (2012). *Hadoop for Dummies Special Edition*, John Wiley & Sons Canada.
- Sebastiani F (2002). Machine learning in automated text categorization. *ACM computing surveys (CSUR)*, 34(1), 1-47.
- Sevli O (2019). Göğüs kanseri teşhisinde farklı makine öğrenmesi tekniklerinin performans karşılaştırması. *Avrupa Bilim ve Teknoloji Dergisi*, (16), 176-185.
- Shahbazi Z & Byun YC (2020). A procedure for tracing supply chains for perishable food based on blockchain, machine learning and fuzzy logic. *Electronics*, 10(1), 41.
- Shakil MH, Munim ZH, Dushenko M, Jimenez VJ & Imset M (2020). Big data and artificial intelligence in the maritime industry: a bibliometric review and future research directions. *Maritime Policy & Management*, 47(5), 577-597.
- Sharma LK, Sirdesai NN, Sharma KM & Singh TN (2018). Experimental study to examine the independent roles of lime and cement on the stabilization of a mountain soil: A comparative study. *Applied Clay Science*, 152, 183-195.

- Shehab N, Badawy M & Arafat H (2021). Big data analytics and preprocessing. *Machine learning and big data analytics paradigms: analysis, applications and challenges*, 25-43.
- Shu H (2016). Big data analytics: six techniques. *Geo-spatial Information Science*, 19(2), 119-128.
- Shukla RK, Garg D & Agarwal A (2011). *Understanding of supply chain: A literature review*. *International Journal of Engineering Science and Technology*, 3(3), 2059-2072.
- Simchi-Levi D & Diabat A (2009). *A carbon-capped supply chain network problem*. In 2009 IEEE international conference on industrial engineering and engineering management (pp. 523-527). IEEE.
- Singh D & Reddy CK (2015). A survey on platforms for big data analytics. *Journal of big data*, 2(1), 1-20.
- Singh VK, Singh D & Singh TN (2001). Prediction of strength properties of some schistose rocks from petrographic properties using artificial neural networks. *International Journal of Rock Mechanics and Mining Sciences*, 38(2), 269-284.
- Šikšnys L & Pedersen TB (2016). Solvedb: Integrating optimization problem solvers into sql databases. In *Proceedings of the 28th International Conference on Scientific and Statistical Database Management* (pp. 1-12).
- Smykay EW, Bowersox DJ & Mossman FH (1961). *Physical Distribution-Management*, New York: Macmillan Publishing Co , 1961.
- Snyder LV, Scaparra MP, Daskin MS & Church RL (2006). *Planning for disruptions in supply chain networks*. In *Models, methods, and applications for innovative decision making* (pp. 234-257). Informs.
- Song X, Wang C, Gao J & Hu X (2013). DLRDG: distributed linear regression-based hierarchical data gathering framework in wireless sensor network. *Neural Computing and Applications*, 23, 1999-2013.
- Southern RN (2011). *Historical perspective of the logistics and supply chain management discipline*. *Transportation Journal*, 50(1), 53-64.
- Spekman RE, Kamauff J & Spear J (1999). Towards more effective sourcing and supplier management. *European journal of purchasing & supply management*, 5 (2), 103-116.

- Spekman RE, Spear J & Kamauff J (2002). Supply chain competency: learning as a key component. *Supply chain management: An international journal*, 7(1), 41-55.
- Staudenmayer J, Pober D, Crouter S, Bassett D & Freedson P (2009). An artificial neural network to estimate physical activity energy expenditure and identify physical activity type from an accelerometer. *Journal of applied physiology*.
- Steinberg F, Burggräf P, Wagner J, Heinbach B, Saßmannshausen T & Brintrup A (2023). A novel machine learning model for predicting late supplier deliveries of low-volume-high-variety products with application in a German machinery industry. *Supply Chain Analytics*, 1, 100003.
- Stern HS (1996). Neural networks in applied statistics. *Technometrics*, 38(3), 205-214.
- Stevens GC (1990). Successful supply-chain management. *Management Decision*.
- Strobl C, Malley J & Tutz G (2009). An introduction to recursive partitioning: rationale, application, and characteristics of classification and regression trees, bagging, and random forests. *Psychological methods*, 14(4), 323.
- Sucky E (2005). Inventory management in supply chains: A bargaining problem. *International Journal of Production Economics*, 93, 253-262.
- Suhr DD (2005). Principal component analysis vs. exploratory factor analysis. *SUGI 30 proceedings*, 203, 230.
- Sun X, Xiao B, Wei F, Liang S & Wei Y (2018). Integral human pose regression. *In Proceedings of the European conference on computer vision (ECCV)* (pp. 529-545).
- Suthaharan S (2016). Support vector machine. *Machine learning models and algorithms for big data classification: thinking with examples for effective learning*, 207-235.
- Sutton RS & Barto AG (2018). *Reinforcement learning: An introduction*. MIT press.
- Syarif AR & Gata W (2017). Intrusion detection system using hybrid binary PSO and K-nearest neighborhood algorithm. *In 2017 11th International Conference on Information & Communication Technology and System (ICTS)* (pp. 181-186). IEEE.
- Szarvas G, Farkas R & Kocsor A (2006). A multilingual named entity recognition system using boosting and c4.5 decision tree learning algorithms. *In Discovery Science: 9th International Conference, DS 2006, Barcelona, Spain, October 7-10, 2006. Proceedings 9* (pp. 267-278). Springer Berlin Heidelberg.

- Szkoła J, Pancierz K & Warchoń J (2011). Recurrent neural networks in computer-based clinical decision support for laryngopathies: an experimental study. *Computational Intelligence and Neuroscience*, 2011, 7-7.
- Talluri S (2000). *An IT/IS acquisition and justification model for supply-chain management*. International Journal of Physical Distribution & Logistics Management.
- Tamura S & Tateishi M (1997). Capabilities of a four-layered feedforward neural network: four layers versus three. *IEEE Transactions on Neural Networks*, 8(2), 251-255.
- Tan LK, Liew YM, Lim E & McLaughlin RA (2017). Convolutional neural network regression for short-axis left ventricle segmentation in cardiac cine MR sequences. *Medical image analysis*, 39, 78-86.
- Tan S & Mayrovouniotis ML (1995). Reducing data dimensionality through optimizing neural network inputs. *AIChE Journal*, 41(6), 1471-1480.
- Taylor DH (1997). *Global cases in logistics and supply chain management*. Cengage Learning EMEA.
- Teoh EJ, Tan KC & Xiang C (2006). Estimating the number of hidden neurons in a feedforward network using the singular value decomposition. *IEEE Transactions on Neural Networks*, 17(6), 1623-1629.
- Thomas DJ & Griffin PM (1996). Coordinated supply chain management. *European journal of operational research*, 94(1), 1-15.
- Tjahjono B, Esplugues C, Ares E & Pelaez G (2017). What does industry 4.0 mean to supply chain?. *Procedia manufacturing*, 13, 1175-1182.
- Tomppo E & Halme M (2004). Using coarse scale forest variables as ancillary information and weighting of variables in k-NN estimation: a genetic algorithm approach. *Remote Sensing of Environment*, 92(1), 1-20.
- Topal M, Eyduran E, Yağanoğlu AM, Sönmez A & Keskin S (2010). Çoklu doğrusal bağlantı durumunda ridge ve temel bileşenler regresyon analiz yöntemlerinin kullanımı. *Atatürk Üniversitesi Ziraat Fakültesi Dergisi*, 41(1), 53-57.
- Toptaş O & Şen A (2021). Eğitimde Ölçme Değerlendirmede Büyük Verinin Önemi. *Düşünce ve Toplum Sosyal Bilimler Dergisi*, 3(4), 223-243.
- Tsai CW, Lai CF, Chao HC & Vasilakos AV (2015). Big data analytics: a survey. *Journal of Big data*, 2(1), 1-32.

- Tu JV (1996). Advantages and disadvantages of using artificial neural networks versus logistic regression for predicting medical outcomes. *Journal of clinical epidemiology*, 49(11), 1225-1231.
- Tuğba SARI & Gül BS (2022). Bütünleşik Zaman Serisi Analizi İle Talep Tahmini: İlaç Tedarik Zincirinde Bir Uygulama. *Verimlilik Dergisi*, (4), 597-610.
- Turkson RF, Yan F, Ali MKA & Hu J (2016). Artificial neural network applications in the calibration of spark-ignition engines: An overview. *Engineering science and technology, an international journal*, 19(3), 1346-1359.
- Tutkun Hİ (2007). Tedarik zinciri yönetimi yapısının tasarlanması ve örgütlenmesi öncesinde işletme de uygulanabilirliğinin analizi. DEÜ Sosyal Bilimleri Enstitüsü.
- Tyagi AK & Chahal P (2022). Artificial intelligence and machine learning algorithms. *In Research Anthology on Machine Learning Techniques, Methods, and Applications* (pp. 421-446). IGI Global.
- Ünver Ö, Gamgam H & Altunkaynak B (2021). *Temel İstatistik Yöntemler*. Seçkin Yayıncılık.
- Vapnik V (1999). U.S. Patent No. 5,950,146. Washington, DC: U.S. Patent and Trademark Office.
- Varian HR (2014). Big data: New tricks for econometrics. *Journal of Economic Perspectives*, 28(2), 3-28.
- Vergara FE, Khouja M & Michalewicz Z (2002). *An evolutionary algorithm for optimizing material flow in supply chains*. *Computers & Industrial Engineering*, 43(3), 407-421.
- Viceconti M, Hunter P & Hose R (2015). Big data, big knowledge: big data for personalized healthcare. *IEEE journal of biomedical and health informatics*, 19(4), 1209-1215.
- Vicente, M. R., López-Menéndez, A. J., & Pérez, R. (2015). Forecasting unemployment with internet search data: Does it help to improve predictions when job destruction is skyrocketing?. *Technological Forecasting and Social Change*, 92, 132-139.
- Yeşilkanat C, Kobyay Y, Taşkın H & Çevik U (2017). Spatial interpolation and radiological mapping of ambient gamma dose rate by using artificial neural

- networks and fuzzy logic methods. *Journal of Environmental Radioactivity*, 175-176: 78-93.
- Wamba FS, Gunasekaran A, Dubey R & Ngai EW (2018). Big data analytics in operations and supply chain management. *Annals of Operations Research*, 270, 1-4.
- Wang H, Lei Z, Zhang X, Zhou B & Peng J (2016). Machine learning basics. *Deep learning*, 98-164.
- Wang L, Lin ZQ & Wong A (2020). Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest x-ray images. *Scientific reports*, 10(1), 1-12.
- Wang M, Hui G, Pang Y, Wang S & Chen S (2023). Optimization of machine learning approaches for shale gas production forecast. *Geoenergy Science and Engineering*, 226, 211719.
- Watkins CJ (1989). *Learning from delayed rewards*.
- Watkins CJ & Dayan P (1992). Q-learning. *Machine learning*, 8, 279-292.
- Wenzel H, Smit D & Sardesai S (2019). A literature review on machine learning in supply chain management. In *Artificial Intelligence and Digital Transformation in Supply Chain Management: Innovative Approaches for Supply Chains. Proceedings of the Hamburg International Conference of Logistics (HICL)*, Vol. 27 (pp. 413-441). Berlin: epubli GmbH.
- White H (1989). Learning in artificial neural networks: A statistical perspective. *Neural computation*, 1(4), 425-464.
- Widrow B & Hoff ME (1960). Adaptive switching circuits. *Stanford Univ Ca Stanford Electronics Labs*.
- Wold S, Esbensen K & Geladi P (1987). Principal component analysis. *Chemometrics and intelligent laboratory systems*, 2(1-3), 37-52.
- Wuest T, Weimer D, Irgens C & Thoben KD (2016). Machine learning in manufacturing: advantages, challenges, and applications. *Production & Manufacturing Research*, 4(1), 23-45.
- Xie L, Li Z, Zeng J & Kruger U (2016). Block adaptive kernel principal component analysis for nonlinear process monitoring. *AIChE Journal*, 62(12), 4334-4345.

- Yang L, Zhang Q & Ji J (2017). *Pricing and carbon emission reduction decisions in supply chains with vertical and horizontal cooperation*. *International Journal of Production Economics*, 191, 286-297.
- Yegnanarayana B (2009). *Artificial neural networks*. PHI Learning Pvt. Ltd..
- Yıldız A (2018). *Endüstri 4.0 İle bütünleştirilmiş dijital tedarik zinciri*. *Business and Management Studies: An International Journal*.
- Yin S & Kaynak O (2015). *Big data for modern industry: challenges and trend*. *Proceedings of the IEEE*, 103(2), 143-146.
- Womack JP, Jones DT & Roos D (1990) *The Machine that Changed the World*, Mandarin Books, London.
- Zhan C, Sankaran S, LeMoine V, Graybill J & Mey DOS (2019). Application of machine learning for production forecasting for unconventional resources. *In Unconventional Resources Technology Conference*, Denver, Colorado, 22-24 July 2019 (pp. 1945-1954). *Unconventional Resources Technology Conference (URTeC)*; Society of Exploration Geophysicists.
- Zhang H, Xu Y & Zhang J (2009). Reproducing Kernel Banach Spaces for Machine Learning. *Journal of Machine Learning Research*, 10(12).
- Zhang Z, Gao M, Yu G, Arık SÖ, Davis LS & Pfister T (2020). Consistency-based semi-supervised active learning: Towards minimizing labeling cost. *In Computer Vision–ECCV 2020: 16th European Conference, Glasgow, UK, August 23–28, 2020, Proceedings, Part X 16* (pp. 510-526). Springer International Publishing.
- Zhao T, Hu Y & Wang Y (2018). Statistical interpretation of spatially varying 2D geo-data from sparse measurements using Bayesian compressive sampling. *Engineering Geology*, 246, 162-175.
- Zhou J, Zhang Q & Li X (2021). Fuzzy factorization machine. *Information Sciences*, 546, 1135-1147.
- Zhu X & Goldberg AB (2009). Introduction to semi-supervised learning. *Synthesis lectures on artificial intelligence and machine learning*, 3(1), 1-130.
- Zijm H, Klumpp M, Heragu S & Regattieri A (2019). Operations, logistics and supply chain management: definitions and objectives. *Operations, logistics and supply chain management*, 27-42.

Zsidisin GA, Jun M & Adams LL (2000). *The relationship between information technology and service quality in the dual-direction supply chain: A case study approach*. International Journal of Service Industry Management.





T.C.
NEVŞEHİR HACI BEKTAŞ VELİ ÜNİVERSİTESİ REKTÖRLÜĞÜ
Bilimsel Araştırmalar ve Yayın Etik Kurulu

TOPLANTI SAYISI
6

KARAR SAYISI
2023.06.219.

TOPLANTI TARİHİ
20.06.2023

Üniversitemiz İktisadi ve İdari Bilimler Fakültesi İşletme Bölümü Sayısal Yöntemler Anabilim Dalı Doktora programı öğrencisi Arş. Gör. Serkan DERİCİ'nin "Büyük Veri ve Makine Öğrenmesi Yöntemleriyle IOT Tabanlı Tedarik Zinciri Yönetimi Üzerine Bir Uygulama" isimli doktora tezi hakkında alınan 21.06.2023 tarih ve 2300041358 sayılı başvuru dosyasının görüşülmesi.

2023.06.219. Üniversitemiz İktisadi ve İdari Bilimler Fakültesi İşletme Bölümü Sayısal Yöntemler Anabilim Dalı Doktora programı öğrencisi Arş. Gör. Serkan DERİCİ'nin "Büyük Veri ve Makine Öğrenmesi Yöntemleriyle IOT Tabanlı Tedarik Zinciri Yönetimi Üzerine Bir Uygulama" isimli doktora tezi hakkında alınan 21.06.2023 tarih ve 2300041358 sayılı başvuru dosyası görüşüldü.

Yapılan görüşmeler sonucunda, aşağıdaki tabloda isimleri belirtilen araştırmacılar tarafından hazırlanan "*Büyük Veri ve Makine Öğrenmesi Yöntemleriyle IOT Tabanlı Tedarik Zinciri Yönetimi Üzerine Bir Uygulama*" isimli doktora tezi ve ilgili belgeler araştırmanın gerekçe, amaç, yaklaşım ve yöntemleri dikkate alınarak incelenmiş olup, projenin gerçekleştirilmesinde etik sakınca bulunmadığına kurulumuz üyeleri tarafından oy birliği ile karar verilmiştir.

YÜRÜTÜCÜ	ARAŞTIRMACI/UZMAN
Prof. Dr. Nuri Özgür DOĞAN	Arş. Gör. Serkan DERİCİ

Prof. Dr. Mutluhan AKIN
Kurul Başkanı

Prof. Dr. Fatih ÖZDEMİR
Kurul Üyesi

Prof. Dr. Merter Rahmi
TELKENAROĞLU
Kurul Üyesi

Prof. Dr. Lütfi BUYRUK
Kurul Üyesi

Prof. Dr. Ensar ÇETİN
Kurul Üyesi

Prof. Dr. Zübeyde
KUMBIÇAK
Kurul Üyesi

Prof. Dr. Sezer SORGUN
Kurul Üyesi

Prof. Dr. Muhammet Şevki
AYDIN
Kurul Üyesi

Prof. Dr. Suzan ÇOBAN
Kurul Üyesi

Belge Doğrulama Kodu: TTAPAFF

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Belge Takip Adresi:
<https://ubys.nevsehir.edu.tr/ERMS/Record/ConfirmationPage/Index>

Adres: 2000 Evler Mah. Zübeyde Hanım Cad. 50300 / Nevşehir

Bilgi için :

Leyla Karagedik
Sekreteryaya

Telefon No:

Faks No:

e-Posta:

İnternet Adresi:

Telefon No:

(0 384) 2281000 - 10064

Kep Adresi: nevsehiruniversitesi@hs01.kep.tr

