T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

METİN MADENCİLİĞİ TEKNİKLERİNİ KULLANARAK FAALİYET BAZLI PROJE YÖNETİMİNDE BİLGİ YÖNETİMİ SÜREÇLERİ İÇİN DERİN ÖĞRENME MODELİ

Esra KARASU

DANIŞMAN
Dr. Öğr. Üyesi Ersin NAMLI

Endüstri Mühendisliği Anabilim Dalı

Endüstri Mühendisliği Programı

İSTANBUL-2019

Bu çalışma, 21.10.2019 tarihinde aşağıdaki jüri tarafından Endüstri Mühendisliği Anabilim Dalı, Endüstri Mühendisliği Programında Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Dr. Öğr. Üyesi Ersin NAMLI (Danışman)
İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi

Prof. Dr. Mehmet Mutlu YENİSEY
İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi

Dr. Öğr. Üyesi Murat Taha BİLİŞİK
İstanbul Kültür Üniversitesi
İktisadi ve İdari Bilimler Fakültesi

20.04.2016 tarihli Resmi Gazete'de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi-Cerrahpaşa'nın abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü'nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

ÖNSÖZ

Tez çalışmam boyunca her türlü konuda bana yardımcı olan ve desteğini esirgemeyen değerli hocam Dr. Öğr. Üyesi Ersin NAMLI'ya sonsuz teşekkürlerimi sunarım.

Tezin uygulama kısmında bilgi ve birikimlerini benimle paylaşan değerli hocam Dr. Öğr. Üyesi Ramazan ÜNLÜ'ye teşekkür eder, saygılarımı sunarım.

Lisans eğitimime başladığım günden itibaren ihtiyaç duyduğum her anda yanımda olan biricik dostum Ebru KOCABAŞ'a teşekkürü bir borç bilirim.

Hayatımın her anında olduğu gibi, eğitim hayatım boyunca da beni destekledikleri ve yanımda oldukları için değerli aileme çok teşekkür ederim.

Ekim 2019 Esra KARASU

İÇİNDEKİLER

Sayfa No

ÖNSÖZ ..... **iv**
İÇİNDEKİLER ..... **v**
ŞEKİL LİSTESİ ..... **viii**
TABLO LİSTESİ ..... **x**
SİMGE VE KISALTMA LİSTESİ ..... **xi**
ÖZET ..... **xii**
SUMMARY ..... **xiv**
1. GİRİŞ **1**
2. GENEL KISIMLAR **3**
2.1. VERİ, ENFORMASYON, BİLGİ 3
2.1.1. Veri 3
2.1.2. Enformasyon 4
2.1.3. Bilgi 5
2.2. BİLGİ ENFORMASYONDAN NE KADAR FARKLIDIR? 7
2.3. BİLGİNİN SINIFLANDIRILMASI 8
2.3.1. Düzenlenme ve Kullanım Tarzına Göre Bilgi Türleri 8
2.3.1.1. İdealist Bilgi 8
2.3.1.2. Sistematik Bilgi 8
2.3.1.3. Pragmatik Bilgi 8
2.3.1.4. Otomatik Bilgi 9
2.3.2. Kaynağına Göre Bilgi Türleri 9
2.3.2.1. Örtülü bilgi 9
2.3.2.2. Açık Bilgi 10
2.3.2.3. Örtülü ve Açık Bilgi Arasındaki Etkileşim 12
2.3.3. Niteliğine Göre Bilgi Türleri 13
2.3.3.1. İnsan Kapitali 13
2.3.3.2. Yapısal Kapital 13
2.3.3.3. Müşteri Kapitali 13

2.4. BİLGİ YÖNETİMİ 14
2.4.1. Bilgi Yönetimi Sistemi ile Veri Ambarı Arasındaki Fark 16
2.4.1.1. Yönetilen Enformasyon Tipleri 16
2.4.1.2. Bağlam 16
2.4.1.3. Boyut 17
2.4.1.4. İçerik Odağı 17
2.4.1.5. Başarım 17
2.4.1.6. İletişim Ağları 17
2.4.2. Bilgi Yönetiminin Temelleri 17
2.4.2.1. Bilgi Yönetiminin Temel Adımları 18
2.4.2.2. Bilgi Yönetiminin Temel Eylemleri 18
2.5. BİLGİ YÖNETİMİ PRENSİPLERİ 19
2.6. BİLGİ DÜZEYLERİ 20
2.6.1. Care-Why (Bilgiyi Niçin Koruyalım) 20
2.6.2. Know-Why (Niçin Bilgi) 20
2.6.3. Know-How (Var Olan Bilgi Birikimi) 21
2.6.4. Know-What (Ne için Bilgi) 21
2.7. DERİN ÖĞRENME (DEEP LEARNING) 21
2.8. DERİN ÖĞRENMENİN TARİHÇESİ 24
2.9. DERİN ÖĞRENME SÜRECİ 26
2.10. DERİN ÖĞRENME MİMARİLERİ 26
2.10.1. Evrişimli Sinir Ağları 26
2.10.2. Tekrarlayan Sinir Ağları 33
2.10.3. Uzun Kısa Süreli Bellek Ağları 35
2.10.4. Kısıtlı Boltzman Makineleri 44
2.10.5. Derin Oto-Kodlayıcılar 45
2.11. METİN MADENCİLİĞİ 47
2.11.1. Metin Madenciliği Adımları 48
2.11.1.1. Metin Önişleme 49
2.11.1.2. Metin Dönüşümü (Öznitellik Üretimi) 51
2.11.1.3. Öznitelik Seçimi 52
2.11.1.4. Veri Madenciliği 52
2.11.1.5. Yorum ve Değerlendirme 52
2.11.2. Metin Madenciliği Teknikleri 52

2.11.2.1. Bilgi Çıkarımı (Information Extraction) 52
2.11.2.2. Kategorizasyon (Categorization) 53
2.11.2.3. Kümeleme (Clustering) 53
2.11.2.4. Görselleştirme (Visualization) 54
2.11.2.5. Özetleme (Summarization) 54
2.11.3. Metin Madenciliği Uygulama Alanları 55
2.11.3.1. Doğal Dil İşleme (Natural Language Processing) 55
2.11.3.2. Bilgi Getirimi/Erişimi (Information Retrieval) 55
2.11.3.3. Bilgi Çıkarımı Sistemleri (Information Extraction Systems) 55
2.11.3.4. Soru Cevaplama Sistemleri (Question Answering Systems) 56
2.12. MODEL PERFORMANS DEĞERLENDİRME ÖLÇÜTLERİ 56
2.12.1. Karmaşıklık Matrisi (Confusion Matrix) 56
2.12.2. Doğruluk Oranı (Accuracy) 57
2.12.3. Kesinlik (Precision) 58
2.12.4. Anma (Recall) 58
2.12.5. F-Ölçütü (F-Score) 58
2.13. LİTERATÜR İNCELEMESİ 59
3. MALZEME VE YÖNTEM 62
3.1. PROBLEMİN TANIMI 62
3.2. VERİ SETİ 66
3.3. DERİN ÖĞRENME ALGORİTMALARININ UYGULANMASI 66
3.3.1. CNN Algoritmasının Uygulanması 67
3.3.2. BLSTM Ağı Algoritmasının Uygulanması 69
4. BULGULAR 72
5. TARTIŞMA VE SONUÇ 77
KAYNAKLAR 79
ÖZGEÇMİŞ 89

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: Derin Öğrenme, Makine Öğrenmesi ve Yapay Zekâ Arasındaki İlişki [14]. 22

Şekil 2.2: Makine Öğrenmesi ve Derin Öğrenme Arasındaki Performans Farkı [16]. 22

Şekil 2.3: Derin Sinir Ağlarının Genel Yapısı [19]. 24

Şekil 2.4: Derin Öğrenme, Makine Öğrenmesi ve Yapay Zekânın Tarihsel Değişimi [28]. 26

Şekil 2.5: Genel CNN Mimarisi [38]. 28

Şekil 2.6: Evrişim İşlemi [38]. 30

Şekil 2.7: Max Pooling İşlemi [46]. 32

Şekil 2.8: Sinir Ağına Dropout (Seyreltme) Uygulanması [48]. 32

Şekil 2.9: Tekrarlayan Sinir Ağları İçerisindeki Döngü [49]. 34

Şekil 2.10: Açık Hale Getirilmiş Bir Tekrarlayan Sinir Ağları [49]. 35

Şekil 2.11: Kısa Süreli Bağımlılıklar [49]. 36

Şekil 2.12: Uzun Süreli Bağımlılıklar [49]. 36

Şekil 2.13: LSTM Ağı Mimarisi [49]. 38

Şekil 2.14: LSTM Hücre Durumu [49]. 39

Şekil 2.15: Noktasal Çarpım ve Sigmoid Katmanı [49]. 40

Şekil 2.16: LSTM Unutma Kapısı [49]. 41

Şekil 2.17: LSTM Girdi Kapısı Katmanı ve Tanh Katmanı [49]. 42

Şekil 2.18: LSTM Durum Bilgisinin Değişimi ve Aktarımı [49]. 43

Şekil 2.19: LSTM Çıktı Kapısı [49]. 44

Şekil 2.20: Genel Boltzmann Makinesi ve Kısıtlı Boltzmann Makinesi [53]. 45

Şekil 2.21: Bir Oto-Kodlayıcının Şematik Yapısı [56]. 46

Şekil 2.22: Metin Madenciliği Adımları [61]. 49

Şekil 3.1: CNN Modeli Akış Şeması. 64

Şekil 3.2: BLSTM Ağı Modeli Akış Şeması. 65

Şekil 3.3: CNN Modelinin Katmanları. 68

Şekil 3.4: BLSTM Ağının Temel Yapısı [99]. 70

Şekil 3.5: BLSTM Modelinin Katmanları. 71

Şekil 4.1: BLSTM Modeli Eğitim ve Test Verisi Doğruluk Oranı Grafiği (%90 Eğitim-%10 Test). 74

Şekil 4.2: BLSTM Modeli Eğitim ve Test Verisi Kayıp Oranı Grafiği (%90 Eğitim-%10 Test).....74

Şekil 4.3: BLSTM Modeli Karmaşıklık Matrisi (%90 Eğitim-%10 Test). 75

TABLO LİSTESİ

Sayfa No

Tablo 2.1: Veriye Hangi Anlamlar Katılarak Enformasyona Dönüşür: 5C [5].....4

Tablo 2.2: Örtülü ve Açık Bilgi Arasındaki Dört Çeşit Etkileşim [3].....12

Tablo 2.3: İkili Sınıflandırma İçin Karmaşıklık Matrisi [79].....57

Tablo 4.1: Derin Öğrenme Modellerinin Performans Analizi (%90 Eğitim-%10 Test). 72

Tablo 4.2: Derin Öğrenme Modellerinin Performans Analizi (%80 Eğitim-%20 Test). 73

Tablo 4.3: Derin Öğrenme Modellerinin Performans Analizi (%67 Eğitim-%33 Test). 73

SİMGE VE KISALTMA LİSTESİ

Kısaltmalar	Açıklama
BLSTM	:Çift Yönlü Uzun Kısa Süreli Bellek (Bidirectional Long Short-Term Memory)
CNN	:Evrişimli Sinir Ağı (Convolutional Neural Network)
HBYS	:Hastane Bilgi Yönetim Sistemi
LSTM	:Uzun Kısa Süreli Bellek (Long Short-Term Memory)
NLP	:Doğal Dil İşleme (Natural Language Processing)
RELU	:Doğrultulmuş Lineer Birim (Rectified Linear Unit)
RBM	:Kısıtlı Boltzmann Makinesi (Restricted Boltzmann Machine)
RNN	:Tekrarlayan Sinir Ağı (Recurrent Neural Network)

ÖZET

METİN MADENCİLİĞİ TEKNİKLERİNİ KULLANARAK FAALİYET BAZLI PROJE YÖNETİMİNDE BİLGİ YÖNETİMİ SÜREÇLERİ İÇİN DERİN ÖĞRENME MODELİ

YÜKSEK LİSANS TEZİ

Esra KARASU

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Endüstri Mühendisliği Anabilim Dalı

Danışman : Dr. Öğr. Üyesi Ersin NAMLI

Bilgisayarların ortaya çıkışından itibaren internet ve iletişim teknolojilerinin de gelişmesiyle insanlar daha fazla bilgiye erişim olanakları bulmuş ve günden güne artan çok sayıdaki veriyi depolamak için veri tabanları oluşturulmuştur. Sürekli artmakta olan bu büyük miktardaki verilerden anlamlı bilgiler edinmek kuruluşlar için hayati bir öneme sahiptir. Dolayısıyla bilginin organize edilip depolanması, paylaşımı, çeşitli yaklaşımlarla anlamlı hale getirilmesi ve güncellenmesi kısacası bilginin yönetimi üzerinde sıkça durulan konu haline gelmiştir.

Son zamanlarda araştırmacılar metin halindeki verilerinden anlamlı bilgiyi edinmek için çalışmalarını metin madenciliği yaklaşımları üzerinde yoğunlaştırmışlardır. Metin madenciliği bir metin kaynağından faydalı bilgiler çıkarmanın yöntemidir. Veri madenciliğinden farklı olarak veri metinlerden oluşmaktadır. Veri tabanlarında bulunan metin halindeki bilgiyi kolayca elde etmek için kategorizasyon yöntemleri uygulanmaktadır. İnsan aracılığıyla

manuel olarak yapılan bu kategorize etme işlemi, veri sayısının sürekli artmasından dolayı bu işlem zahmetli ve zaman alan bir eylem haline gelmiştir. Bu probleme çözüm olarak metin madenciliği yaklaşımları kullanılarak otomatik kategorizasyon modelleri geliştirilmektedir. Bu bağlamda önceden manuel olarak kategorileri tanımlanmış metin belgeleri yardımıyla yeni oluşan metin halindeki verilerin kategorizasyonu yapılabilmektedir.

Bu çalışmanın amacı, "projelerde bilgi süreçleri için metin madenciliği teknikleri kullanılarak bir derin öğrenme modeli" oluşturmaktır. Çalışmada, bir yazılım projesinin test aşamasında ortaya çıkan Türkçe metinlerden oluşan problemleri sınıflandırmak için derin öğrenme esaslı sınıflandırma metodolojileri kullanılmıştır. Derin öğrenme modellerinin oluşturulmasında, Evrişimli Sinir Ağları (Convolutional Neural Networks, CNN) ve Çift Yönlü Uzun Kısa Süreli Bellek (Bidirectional Long Short-Term Memory, BLSTM) Ağları yöntemleri uygulanmıştır.

Ekim 2019 104 sayfa.

Anahtar kelimeler: Bilgi yönetimi, metin madenciliği, derin öğrenme, evrişimli sinir ağları, çift yönlü uzun kısa süreli bellek ağları.

SUMMARY

DEEP LEARNING MODEL FOR KNOWLEDGE MANAGEMENT PROCESSES IN ACTIVITY BASED PROJECT MANAGEMENT USING TEXT MINING TECHNIQUES

M.Sc. THESIS

Esra KARASU

Istanbul University-Cerrahpasa

Institute of Graduate Studies

Department of Industrial Engineering

Supervisor : Assist. Prof. Dr. Ersin NAMLI

Since the advent of the computers, with the development of internet and communication technologies, people have access to more information and databases have been created to store a growing number of data. It is vital for organizations to gain meaningful information from this ever-increasing amount of data. Therefore, organizing and storing information, sharing it, making it meaningful and updating it with various approaches, in short, management of information has become a topic that is frequently emphasized.

Recently, researchers have intensified their studies on text mining approaches to obtain meaningful information from textual data. Text mining is a method of extracting useful information from a text source. Unlike data mining, data consists of texts. Categorization methods are applied in order to obtain the information in text form in the databases easily. This categorization process, which is performed manually by human, has become a laborious and time-consuming action due to the continuous increase in the number of data. As a

solution to this problem, automatic categorization models are developed by using text mining approaches. In this context, categorization of newly formed text data can be done with the help of text documents whose categories are defined manually.

The aim of this study is to create a deep learning model for knowledge processes in projects by using text mining techniques. In this study, deep learning based classification methodologies have been used to classify the problems arising during the testing phase of a software project consisting of Turkish texts. In constructing deep learning models, Convolutional Neural Networks (CNN) and Bidirectional Long Short-Term Memory (BLSTM) Networks has been applied.

October 2019 104 pages.

Keywords: Knowledge management, text mining, deep learning, convolutional neural networks, bidirectional long short-term memory networks.

1. GİRİŞ

1960'lı yıllardan itibaren, veri tabanı ve bilgi teknolojisi, ilkel dosya işleme sistemlerinden çok yönlü ve güçlü veri tabanı sistemlerine kadar sistematik olarak gelişmiştir. “Bilgi çağında yaşıyoruz” popüler bir sözdür; ama aslında veri çağında yaşıyoruz. Terabaytlarca veri, bilgisayar ağlarımıza, Dünya Çapında Ağ’a ve çeşitli veri depolama cihazlarına her gün iş dünyası, toplum, bilim ve mühendislik, tıp ve günlük yaşamın hemen hemen her yönünden aktarılmaktadır. Mevcut veri hacmindeki bu patlayıcı büyüme, toplumumuzun bilgisayarlaştırılmasının ve güçlü veri toplama ve depolama araçlarının hızla gelişmesinin bir sonucudur [1]. Artık bu gelişmeler doğrultusunda bilgiye erişim kolaylaşmış ve büyük bir bilgi yığılması meydana gelmiştir. Sürekli artmakta olan veriden anlamlı bilgilerin çıkarılması ve dolayısıyla bilginin yönetilmesi kuruluşlar için büyük bir öneme sahip olmuştur.

Metin madenciliği, genel olarak, bir kullanıcının bir dizi analiz aracı kullanarak bir belge koleksiyonuyla etkileşime girdiği, bilgi yoğun bir süreç olarak tanımlanabilir. Veri madenciliğine benzer şekilde, metin madenciliği, ilginç kalıpların tanımlanması ve araştırılması yoluyla veri kaynaklarından faydalı bilgiler çıkarmayı amaçlamaktadır. Bununla birlikte, metin madenciliğinde veri kaynakları belge koleksiyonlarıdır ve ilginç modeller resmi veri tabanı kayıtları arasında değil, bu koleksiyonlardaki dokümanlardaki yapılandırılmamış metin verilerinde bulunur [2].

Metin madenciliği tekniklerinden olan metin kategorizasyonu (veya metin sınıflandırma) metin belgelerini önceden tanımlanmış kategorilere atama yöntemidir. Bu kapsamda derin öğrenme algoritmaları metin belgelerini belirli kategorilerde sınıflandırmak için kullanılmaktadır.

Bu tez çalışmasında, yazılım projelerinin test aşamasında meydana gelen problemlerin yer aldığı metin halindeki belgeleri sınıflandırmak için bir derin öğrenme modeli oluşturulmuştur. Derin öğrenme modellerinin oluşumunda Evrişimli Sinir Ağları (CNN) ve Çift Yönlü Uzun Kısa Süreli Bellek (BLSTM) Ağları algoritmaları kullanılmıştır.

Tezin genel kısımlar bölümünde, ilk olarak bilgi kavramı ve bilgi yönetiminden detaylı bir şekilde bahsedilmiştir. Daha sonra çalışmanın ana konusu olan metin madenciliği, derin öğrenme yöntemleri, model performans ölçütleri ile ilgili ayrıntılı anlatımlar yapılmıştır. Son olarak metin madenciliği ile ilgili çalışmaların yer aldığı literatür incelemesi sunulmuştur.

Malzeme ve Yöntem bölümünde, ilk olarak mevcut problem tanımlanmış, veri setinin nasıl oluşturulduğundan bahsedilmiştir. Daha sonra, CNN ve BLSTM algoritmaları ile oluşturulan derin öğrenme modelleri %90'a %10 ayırma, %80'e %20 ayırma ve %67'ye %33 ayırma metotları ile test ve eğitim seti olarak ayrılan veri üzerine uygulanmış ve metin verilerinin kategorizasyonu yapılmıştır.

Bulguların yer aldığı bölümde, uygulanan derin öğrenme modellerinin performans değerleri sunulmuştur. CNN ve BLSTM algoritmaları ile oluşturulan modellerin başarısı model performans ölçütlerine göre karşılaştırılmıştır. Sonuçların karşılaştırılmasında; doğruluk oranı, kesinlik, anma, F-ölçütü ve karmaşıklık matrisi gibi performans ölçütleri kullanılmıştır. En iyi performansa sahip modelin doğruluk oranı ve kayıp oranı grafikleri ortaya koyulmuştur. Ayrıca karmaşıklık matrisi de oluşturularak değerlendirmeler yapılmıştır.

Çalışmanın son kısmı olan tartışma ve sonuç bölümünde ise sonuçlar özetlenmiş, çalışmanın katkılarından bahsedilmiş ve çalışmanın gelişmesine katkı sağlayacak önerilere yer verilmiştir.

2. GENEL KISIMLAR

2.1. VERİ, ENFORMASYON, BİLGİ

2.1.1. Veri

Veri (Data), kurumsal amaçlar doğrultusunda işlemlerin yapılandırılmamış bir şekilde kaydedilip saklanmasıdır. Yaşadığımız çağa uygun organizasyonlarda veri, gelişmiş veri sistemlerinde depolanır. Veri, bir anlamı ve bir içeriği olmayan yapısallaştırılmamış gerçekler olarak tanımlanmaktadır [3].

Veri sayılardır. Sayısal nicelikler veya gözlem, deney veya hesaplamadan türetilen diğer özelliklerdir [4].

Bir dükkân açısından veri; bir olay hakkında bir dizi özel ve objektif açıklamalar ile yapılmış bir alışverişin yapısal kayıtlarından oluşan bir olaydır. Bir firma açısından bakıldığında, veriler bir faaliyetle veya bir işlemin yapılandırılmış kaydıyla ilgili belirli ve nesnel bilgiler kümesidir. Aksiyon, markette bir ürünün satın alınması ya da hayatınızın tasarrufu olacak borsadaki hisse senedi fiyatının değişmesi olabilir. Bu rakamlar kendi başlarına anlamlı bir şey söylemez. Örneğin bir marketten yapılan bir işlem, satın aldığınız ürünün markasının bugün diğerlerinden daha fazla satıp satmadığını, bu mağazada mı yoksa ülke çapında mı olduğunu ve dün yapıp yapmadığını söylemez. Benzer bir şekilde, hisse senedi fiyatları, şirketin dün olduğundan daha iyi bir performans gösterip göstermediğini veya bu sabah hisse senetlerini satmış olmanızın bir düşüşte olup olmayacağını size söylemez. Bu anlam, bu ham gerçeklere ve rakamlara, bir tür bilgi biçimine dönüştürüldüklerinde gelir. Ham verinin kendi içinde bir amacı olmasına rağmen, ilgisi az olabilir veya hiç olmayabilir.

Veri yönetimi hakkında konuşulduğunda, kararlar çoğunlukla niceldir. Bir saat içinde ne kadar veri işlenebiliyor, bir işlem yapmanın maliyeti ne kadar, ne kadar kapasiteye sahibiz vb. Nitel önlemler ikincil olarak kabul edilir. Bu önlemler, ihtiyaç duyulduğunda verilerin zamanında bulunabilirliği ve ihtiyaç duyulan verilerin kolayca alınabilir olup olmadığı gibi konuları ele almaktadır [5].

2.1.2. Enformasyon

Enformasyon (Information), belirli bir nesne, olay veya süreçle ilgili bir veri topluluğudur ve ilişkili açıklamalar, yorumlar ve diğer metinsel materyallerdir [4].

Enformasyon düzenlenen veridir. Bu işlem başka kişiler tarafından yapılmaktadır. Bir anlam ifade etmesi kişinin ilgisinin olmasına bağlıdır. Örnek verilecek olursa, "10.30 – 12.00 İstanbul-Giresun TK7333 20A" ifadesi uçak ile yolculuk edecek olan bir yolcu için anlamlı olabilir. Enformasyon veriden daha çok anlam içeren, yazılı, sözlü veya görsel bir mesajdır. Enformasyonun iletilmesi için bir gönderici ve bir alıcı olmalıdır. Enformasyon, alıcının algısının değişimi ve yargısını etkilemeyi hedeflemektedir [3]. Veri, bir değer katılarak enformasyona dönüştürülürken Tablo 2.1'deki 5C metodu kullanılır [5].

Tablo 2.1: Veriye Hangi Anlamlar Katılarak Enformasyona Dönüşür: 5C [5].

VERİYE KATILAN	SONUÇ
Yoğunlaştırma (Condensed)	Verinin özeti çıkarılır, sıkıştırılıp lüzumsuz anlam derinliği yok edilir.
Bağlamsallaştırma (Contextualized)	Verilerin neden toplandığı bilinir.
Hesaplama (Calculated)	İncelenen veri yoğun hale getirilmiş veri gibi olur.
Sınıflandırma (Categorized)	Analiz ünitesi bilinir.
Düzeltme (Corrected)	Yanlışlıklar düzeltilerek eksik "veri delikleri" yamanır.

2.1.3. Bilgi

Bilgi (knowledge); anlama, farkındalık veya anlayışı geliştirmek için organize, sentezlenmiş veya özetlenmiş enformasyondur. Yani bilgi, meta verilerin bir birleşimidir ve meta verilerin başarıyla uygulanabileceği bağlamın farkındalığıdır [4].

Bilgi kişisel manada düzenlenmiş enformasyon olarak tanımlanabilir. Öğrenme ve tecrübe vasıtasıyla kazanılan bilgiler ile birleşmiştir. Karar ve davranışlara yol gösterir. Bilgi, insanların zihnindedir; yaşamları boyunca öğrendiklerinin ve deneyimle elde ettiklerinin toplamıdır. Kişinin inanç ve değerlerine dayanır.

Bilginin oluşumu için insanlar arasında iletişim yolu ile enformasyon akışı olmalıdır. Alınan enformasyon değerliyse alıcının sahip olduğu bilgi birikimi ile bütünleştirilerek bilginin depolandığı belleğe eklenir. Şayet değerli değilse kabul edilmez ve silinir. "Deneyim ve değerlerle ilişkili enformasyonun akışkan bir karması" olarak tanımlanan bilgi, veri ve enformasyon kavramlarından daha karmaşıktır. Bazen sözlerle ifade edilmesi her zaman mümkün olmayabilir. Verilerden enformasyon oluşturulduğu gibi, enformasyonlardan da bilgi oluşturulur. Bu dönüşümdeki düşünce süreçleri aşağıdaki gibidir [5]:

- Karşılaştırma: Bir durumla ilgili enformasyon bilinen diğer durumlar ile karşılaştırıldığında neyi göstermektedir?
- Varılan sonuçlar: Enformasyonun karar alma ve işe girişme konusunda geldiğimiz son durum nedir?
- İlişkilendirmeler: Bu bilgi kümesi başka bilgi kümeleri ile nasıl ilişkilendirilir?
- Sohbet: Bu bilgi hakkında diğer insanlar ne düşünmektedir?

Bilgi ne veri ne de enformasyondur, her ikisiyle de ilişkilidir ve bu terimler arasındaki farklar genellikle bir derece meselesidir. Hangi verinin, enformasyonun ve bilginin nasıl farklılık gösterdiğine, bu kelimelerin ne anlama geldiğine dair kafa karışıklığı, firmaların ihtiyaç duyduklarını nadiren karşılayan teknoloji girişimleri için muazzam harcamalara neden olmuştur. Genellikle firmalar, bir sisteme yoğun bir şekilde yatırım yapmadan önce neye ihtiyaçları olduğunu anlamamaktadır. Bununla birlikte verilerin, enformasyonun ve bilginin birbiriyle değiştirilebilir kavramlar olmadığını vurgulamak önemlidir.

Örgütsel başarı ve başarısızlık çoğu zaman hangisine ihtiyacınız olduğunu, hangisine sahip olduğunuzu ve her biriyle neler yapabileceğinizi ve yapamayacağınızı bilmenize bağlı olabilir. Bu üç şeyin ne olduğunu ve birinden diğerine nasıl geçtiğinizin anlaşılması, bilginin başarılı bir şekilde çalışmasını sağlamak için esastır [6].

Bilgi öğrenenlerin akıllarından doğar ve gelişir. Bir kurumda yalnızca dokümanlara yansımakla kalmayıp, aynı zamanda kurumsal düzen, kurallar, tecrübeler ve uygulamaları anlatmaktadır. Kısacası; bilgi, yalnızca yaşama geçirilmiş enformasyon demektir. Burada hayata geçirebilirlik, yalnızca doğru zamanda ve doğru yerde, doğru kavramda ve doğru şekilde kazanılan enformasyon anlamındadır. Bu da, bilginin doğru zamanda alınacak yerinde kararların, tahminlerin, tasarımların, planlamaların yükünü taşıyabilmesini mümkün kılar. Bilgi; kişisel ve ortak akıllar tarafından ortaya çıkarılır ve paylaşılır. Veri tabanlarından elde edilmez; deneyimler, başarılar, başarısızlıklar ve öğrenim ile zaman içerisinde kazanılır [5].

Bilgi kısaca potansiyel olarak enformasyondan daha karışık bir kavramdır şeklinde de tanımlanmaktadır [7].

Çoğu insan bilginin veri veya enformasyondan daha geniş, daha derin ve daha zengin olduğu konusunda sezgisel bir düşünceye sahiptir. İnsanlar "bilgili bir bireyden" bahseder ve bir konuyu ayrıntılı, bilgili ve güvenilir bir şekilde kavrayabilen hem eğitimli hem de zeki biri anlamına gelir. Bilgili bireyler veya gruplar tarafından üretilebilse de "bilgili" veya "bilgiyle dolu" bir not, el kitabı veya veri tabanı hakkında konuşmaları pek mümkün değildir. Bilgi, yeni deneyimlerin ve bilgilerin değerlendirilmesi ve bir araya getirilmesine yönelik bir çerçeve sağlayan, belli bir düzen içindeki deneyimler, değerler, bağlamsal bilgi ve uzman görüşünün esnek bir bileşimidir. Bu tanım bilgiyi değerli kılan özellikleri ve karakteristiği aynı şekilde iyi yönetmeyi zorlaştıran özellikleri ifade eder. Bilen kimsenin beyninde yaratılır ve kullanılır. Kurumlarda, genellikle sadece belgelere veya depolara değil aynı zamanda kurumsal rutinlere, süreçlere, uygulamalara ve normlara da gömülüdür [6].

Örneğin, veri, enformasyon ve bilgi hiyerarşisi şu şekilde olabilir:

Veri: Hasta Sıcaklığı: 102 ° F; Nabız: dakikada 109 atım; Yaş: 75.

Enformasyon: “Ateş”, 100 ° F'den yüksek bir sıcaklıktır; “Taşikardi”, dakikada 100 atımdan daha büyük bir nabız atışıdır; “Yaşlı”, 75 yaşından büyük olan bir kişidir.

Bilgi: Hastanın muhtemelen ciddi bir grip vakası vardır [4].

Bilgi, veri ve örgütsel öğrenme terimleri, çeşitli yorumlara ve kullanıma açıktır. Veriler, bilgiyi yönetmek için kendi başına bir sistemde saklanmamalıdır; bunun yerine tarihsel bağlamın eklenmesiyle katma değer bilgisi olarak depolanmalıdır [5]. Bir veri deposunda yer alan veriler, kullanılmadıkları sürece hiçbir değeri yoktur. Bu nedenle bilgi yönetimi bir veri işleme sürecidir; bu veriler ilk önce yakalanır, manipüle edilir ve saklanır ve ardından elde edilen bilgiler kullanıcının ihtiyaçlarına uyacak şekilde paketlenir veya yeniden biçimlendirilir [4].

2.2. BİLGİ ENFORMASYONDAN NE KADAR FARKLIDIR?

Bilgi enformasyonla çok fazla karıştırılır. Bilgiyi bu kavramlardan ayıran esas neden bilginin kişiye has olması ve bazı subjektif düşünme süreçleri sonrasında ortaya çıkmasıdır [3].

Bilgi ile enformasyon arasındaki ilişkiyi ifade eden kabul edilmiş en iyi tanım, onun yalnızca hayata geçirilebilir enformasyon olduğudur. Eğer bilginin nasıl kullanılacağına karar verilirse enformasyon da tartışılarak bilgiye dönüşür. Bilgi için yapılabilecek başka bir tanımlama da kendi çerçevesi içinde elde edilmiş enformasyon olduğudur. Bize yalnızca gerçeği ortaya koyan enformasyonların aksine bilgi, öngörülerde bulunmayı, günlük ilişkileri yürütmeyi ve kararlar almayı sağlar. Bilgi, açık, mutlak ya da yalın değildir. Aksine karmaşık, tartışmaya açık, kısmen yapısal kısmen de temelsizdir. İçgüdüseldir, iletişim kurulması ve kelime ya da şekillerle anlatılması zordur. Ancak en iyi özelliği veri tabanlarına doldurulamayıp insanların beyinlerine kaydedilmesidir. Onlar bir şirketin elemanları olan insanlardır, ilişkiler, karşılıklı konuşmalar, deneye dayalı sezgiler, insanların durum kıyaslaması yapma kabiliyetleri oranında yayılır.

Bilginin çok küçük bir kısmı yazıya dökülerek veri tabanlarına, kitaplara, elyazmalarına, belgelere ve sunumlara geçer. Büyük kısmı insanın aklında kalır. Bu bilgileri şirketteki bilgili insanlar sadece kendileri için depolamadığı sürece hoş bir şeydir. Hâlbuki enformasyon, varlığını arşivlerde korur ve insanlar ayrıldıktan sonra da oradadır.

Bilgi; kazanımı, paylaşılması ve yayılması için resmi ve gayri resmi süreçlerden ve yapılanmalardan geçer. Bilgi çalışanları ve işverenleri şirkete girip uyum sağlama süreci

içinde yoğun bir iletişim (kuruluşa ilk kez ulaştıklarında ve yavaşça paylaşmaya daha istekli olduklarında) ile veri alışverişine girişirler. Bu süreç, sürekli olarak resmi ya da gayri resmi grup tartışmaları ve değişimleri ile devam eder. Enformasyon ise, bunun tersine elde edenin kendinde saklıdır [5].

2.3. BİLGİNİN SINIFLANDIRILMASI

2.3.1. Düzenlenme ve Kullanım Tarzına Göre Bilgi Türleri

Bilginin kullanma biçimi, nasıl algılandığı ve organize edildiğine bağlı olarak değişir. Bu yaklaşımla bilgi aşağıda gösterildiği şekilde dört başlık altında sınıflandırılmaktadır [3].

2.3.1.1. İdealist Bilgi

Bu bilgi türü vizyon oluşturmayı, amaç belirlemeyi, değer ve inançları yönlendirmeyi ve kararlar almayı sağlar. Yeni teoriler oluştururken idealist bilgi düşünce seçeneklerinin üretilmesine yardımcı olur. İnsanların okudukları, yaptıkları ve tartıştıkları şeyler idealist bilginin kaynağıdır. Bunlar üzerinde düşündükçe paradigmalar oluşturulur. Bu bilgi amaca özgü sentezin yapıldığı ortamlarda değerlendirilir. İlginçtir ki insanlar genellikle bu bilginin farkında değillerdir ve onu ve etkilerini tanımlamadan kullanmaktadırlar.

2.3.1.2. Sistematik Bilgi

Bu bilgi türü, karşılaşılan olaylarla başa çıkmaya çalışılırken başvurulan genellemeleri, modelleri ve düzenlenmiş şekilde gerçeğin algılanmasını sağlamaktadır. Kişi, bir sistemin nasıl çalıştığını, iç düzeneklerini bu bilgiyle anlamaktadır ve değişkenlere müdahale edildiğinde sonuçlarda ne çeşit farklılık olduğunu sistematik bilgiyle çözer. Yöntem ve kılavuz oluşturmaya yarayan bir bilgi türüdür. Sistematik bilginin kaynağı çoğunlukla biçimsel eğitimdir ve gözlemlerden üretilen senaryolar ve modeller de bu bilgiye kaynak oluşturmaktadır. İnsanlar sahip olduğu sistematik bilginin bilincindedir ve bu bilgi kendi içerisinde bütünlük oluşturan alt sistemlerden oluşmaktadır.

2.3.1.3. Pragmatik Bilgi

Faydacı bilgi olarak da adlandırılan bu bilgi türü, insanların bir işi yaparken ve kararlar verirken bilinçli şekilde kullandıkları kurallar, gerçekler ve kavramlardır. Büyük ölçüde *know-how* bilgisidir. Faydacı bilgiye örnek olarak, sorumluluk alanına dahil olan konularda

bir yöneticinin neleri yapması gerektiğini bilmesi verilebilir. Eğitim, verilen talimatlar ve el yordamıyla bulunanlar, bu bilginin kaynaklarıdır.

2.3.1.4. Otomatik Bilgi

İçselleşmiş bilgidir. Düşünmeden gerçekleştirilen eylemler otomatik şekilde sahip olunan bilginin sonucudur. Rutin davranışlar bu bilginin en karakteristik örneklerindendir. İnsanlar alışkanlıklarında, yöntemlerde ve verdikleri tepkilerde içerilmiş olan otomatik bilginin genellikle farkında değillerdir.

Bu tür bilginin kullanım sıklığı kişinin yaptığı işe ve ilişkilerine dar veya geniş çerçeveden bakmasıyla ilgilidir. Dar açıdan bakan bir kişide teknik bilgi fazla olsa da diğer bilgi çeşitleri çok daha az oranda bulunur. Sıralama yapılacak olursa, dar bakış açılı bir bireyde en düşük seviyede bulunan bilgi idealist bilgidir, sonrasında sırayla sistematik, pragmatik ve otomatik bilgiler gelir. Geniş görüşlü kişilerdeyse teknik bilgi nispeten daha az oranda olmasına rağmen dünyaya bakış açısını içeren alandaki diğer bilgi çeşitleri daha ağırlıklı olarak insanın bilgi dünyasında dengeyi sağlamaktadır [3].

2.3.2. Kaynağına Göre Bilgi Türleri

Bilgi, kaynağına göre Örtülü Bilgi ve Açık Bilgi olarak ikiye ayrılmaktadır. Bilgi yönetimi bakımından bu iki temel bilgi türü arasında bir ayrım yapılması gerekir. Bu ayrım, hareket ve durumun kinetik enerjisine benzer [3].

2.3.2.1. Örtülü bilgi

Örtülü bilgi; insanın içinde, zihninde yani kendi belleğinde depoladığı bilgi olarak tanımlanmaktadır. İnsanın içinde o kadar yer etmiştir ki, kişi bazen ona sahip olduğunun bile farkında olmaz ve çok fazla düştüğü bir hatayı yaparak başka insanlarda da aynı bilgilerin benzer seviyede bulunduğunu varsayar [3].

Saklı bilgi olarak da adlandırılan örtülü bilgi, bilinçaltı bir seviyede kökleşmiş olan ve bu nedenle başkalarına açıklanması zor olan bilgidir. Bir uzman makinist, örneğin belirli bir makineyi kullanma konusunda son derece yetenekli olabilir, ancak çıraklara uzmanlığını tam olarak nasıl kopyalayacağı konusunda talimat veremez. Örüntü tanıma becerilerini içeren çoğu bilgi, örtülü bilgi kategorisine girer. Örneğin, deneyimli bir radyolog genellikle hastanın göğsünün tipik bir radyografik filmine bakabilir ve filmin normal veya anormal olup

olmadığına anında karar verebilir. Bununla birlikte, uzman teşhis görevlisinin, karar vermesini sağlamak için kullanılan süreci neredeyse imkânsız hale getirir. Stajyerlere ve öğrencilere radyografik çalışmaları okumayı öğretmek zorunda kaldıklarında, radyologlar sistematik bir yaklaşım kullanır, ilk önce kemiklere bakar, sonra yumuşak dokuları gösterir ve bu şekilde devam eder. Böylece öğrencinin öğrenme sürecine başlayacak bir sırası vardır [4].

Bilgi insanların deneyim ve işleri doğrultusunda zihinlerinde oluşur. Zihinlerde oluşan bu bilgilerin bir kısmı elektronik ortamda veya dokümanlara aktarılabilir fakat en önemli kısımları aktarılamaz. Örtülü bilgi kişiseldir, spesifiktir ve bu yüzden biçimlendirmek ve iletmek zordur, insanların beyninde saklanır [8], [9].

Aynı şirkette çalışan iki kişinin iş güvenlikleri bilgiye bağlıysa, başlangıçta paylaşılsa bile zamanla, ekmeğin aslanın ağzında olduğu anlaşılınca ve hele de bir kriz dönemine girildiği zamanlarda herkesin bilgisini kendine saklama eğilimi hızla artar. Şirketler açısından da durum buna benzer. "Biz başlatırsak diğerleri de takip eder" düşüncesi gelişir ve bu da başarısızlık için birebirdir. Tasarlanmış strateji ne olursa olsun, bilginin yayılmasını ve paylaşılmasını mümkün kılacak şekilde düzenlenmesi gerekir. Bu konuda sağlam bir adım atılmadığı sürece bildiğini kendine saklamak insanın doğasında vardır. Bu olgu, 5 işçi çalıştıran küçük işletmelerde de yüz bin kişilik dev kuruluşlarda da aynıdır. Bunu düzeltmek bilgi yönetiminin görevleri arasındadır [5].

Duyulara hareket becerilerine, bireysel algılamalara, fiziksel deneyimlere, sağduyu kurallarına ve sezgilere bağlı olan saklı bilginin başkalarına açıklanması çok zordur. Organizasyonda saklı bilgi kavramının ne olduğunu çok kişi sezgileriyle anlasa bile yöneticiler saklı bilgi ile uygulama düzeyinde uğraşmakta çok zorlanmaktadırlar. Saklı bilginin değerini anlamak ve ondan nasıl yararlanılacağına karar vermek bilgi üreten bir şirketin en başta gelen uğraşlarından biridir ve bu da bilginin desteklenmesini gerektirir. Saklı bilgi iş ortamında kullanılamayacak ya da sürekli olarak uygulanamayacak kadar gizemli görünebilir; ancak onu yeniliğin güçlü bir aracı yapan da bu değişken koşullara bağlı niteliğidir [9].

2.3.2.2. Açık Bilgi

Hali hazırda konuşulabilen ve yazılabilen bilgidir. Böylece diğer kişiler için ulaşılabilir bilgidir. Sözlerle, resimlerle veya diğer araçlarla biçimsel ve sistematik bir dille ifade edilebilir [3].

Açık bilgi, bir görevde yetkin birinden bir başkasına yazılı veya sözlü iletişim yoluyla kolaylıkla iletilebilir. Bir kek tarifinde, bir araba kapısının bir montaj hattındaki ana şasiye cıvatalanması adımlarında ve kimyasal bir işlem için gerekli olan bileşenlerin listesinde açık bir şekilde belirtilir. Örtülü bilgilerin aksine, açık bilgiler genellikle bir kitapta veya kullanım kılavuzunda bulunabilir [4].

Gerek bireyler gerekse gruplar, yetkin ve ortak hareket etmeyi sağlayan saklı ve açık bilgiye sahiptir. Bir şirkette çalışanlar bir işin gerçekleştirilmesi için yerleşik ve rutinleşmiş, bazen de organizasyonel prosedürlerle resmiyet kazanmış açık toplumsal bilgiyi paylaşabilirler. Ancak açık toplumsal bilgi bile yazılı olarak tümüyle yakalanmaz ya da rutinleştirilmez; bir kısmı sözel olarak ya da örneklerle paylaşılabilir. Toplumsal bilginin büyük bir kısmı saklı bilgidir; somon balığının etine zarar vermeden kılçığının çıkarılması, kaliteli mobilya yapımı için hangi malzemenin seçilmesi gerektiği, düşmeden bisiklete binmek gibi. Ancak bir grup içinde nasıl davranılacağı, stresli bir durumla nasıl başa çıkılacağı ya da nasıl liderlik yapılacağı gibi genel konular da bir topluluğun toplumsal saklı bilgisinin birer parçasıdır.

Bunun anlamı, özellikle de saklı olduğunda ve topluluğun diğer üyeleri ile paylaşıldığında bilginin yalnızca enformasyon demek olmadığıdır. Şirketler bilgi ile enformasyonu aynı sınıfa sokacak olurlarsa, bilginin ve bilgi üretiminin kendine özgü niteliğini göz ardı etmiş olurlar; en kötüsü de, gelişmiş bilişim sistemleri ve ölçüm araçları bilginin yaratıcı yönünü dışarıda bırakabilir. Yönetimi bekleyen gerçek zorluk bilgi üretiminin desteklenmesidir; bilginin yan ürünü olan enformasyonun yakalanması işin kolay tarafıdır [9].

2.3.2.3. Örtülü ve Açık Bilgi Arasındaki Etkileşim

Tablo 2.2: Örtülü ve Açık Bilgi Arasındaki Dört Çeşit Etkileşim [3].

	Örtülü Bilgi'ye	Açık Bilgi'ye
Örtülü Bilgi'den	Sosyalleştirme	Dışsallaştırma
Açık Bilgi'den	İçselleştirme	Birleştirme

Açık ve örtülü bilgi kendi aralarında şekil değiştirebilmektedir. Bir dönüşüm ya da bilgi hareketi olarak da açıklanabilecek bu taşıma, yani bilgiyi bir kişiden diğer bir kişiye aktarma dört şekilde gerçekleşmektedir:

- Dışsallaştırma: Bilinenler somutlaştırıldığında gerçekleşmektedir. Örneğin iyi bilinen bir konuyla ilgili metin yazılabilir. Yazmak, beynin içerisindeki örtülü bilginin başka insanların anlayacağı açık bilgiye dönüştürülme sürecidir.
- İçselleştirme: İnsanın yeni bulduğu bir bilgi parçasını özümlemesi, değerlendirmesi ve yansıtması sonucunda gerçekleşmektedir.
- Birleştirme: Bir konu bir birey veya topluluğa sunulduğunda ya da bir tartışma ortamında bulunulduğunda oluşur. Söylenilecek sözler hazırlanırken örtülü bilgi açık bilgiye dönüşür. Dinleyiciler verilen açık bilgiyi aynı bilgi türü olarak alırlar. Bu bilgi onlar için bir anlam taşıyorsa sonrasında içselleştirme süreci gerçekleşir
- Sosyalleşme: Başka kişilerle etkileşime girildiğinde gerçekleşmektedir ve birçok kere bilinçaltı seviyede bir bilgi aktarımı olur. Bu basit olarak kişinin, birini bir iş yapıyorken seyretmek ve izlediği işe benzeyen bir işi kendisi yaptığında kullanabileceği birtakım faydalı sonuçları çıkartmak, ipuçlarını elde etmektir [3].

2.3.3. Niteliğine Göre Bilgi Türleri

Kuruluşların sahip olduğu nitelikleri dikkate alındığında bilgi üç farklı türe ayrılmaktadır. Bu bilgi türleri aşağıdaki gibidir.

2.3.3.1. İnsan Kapitali

Kişinin sahip olduğu bilginin değerini göstermektedir. Çalışanın meslekte bulunduğu zamanın uzunluğu, nitelikleri, temel yetkinlikleri belli bir seviyede olan kişilerin miktarı, içerde veya dışarda beraber çalışmaları gereken projelerde karşı karşıya gelen çalışanların sayısı gibi unsurlar insan kapitalini oluşturmaktadır. Bilgi yönetiminin hedeflerinden biri de kuruluşların insan kapitalinin değerini yükseltmektir [3].

Organizasyon içindeki kişilerin bilgi, beceri ve yetkinlikleridir. İnsan kapitali, çalışanlara ve yöneticilere ait bir bilgidir. Çalışanların ve yöneticilerin şirketten bir bilgi yönetim sistemi olmadan ayrılmaları durumunda; kendi becerilerini, yeterliliklerini ve bilgilerini yanlarında götürmektedirler [4].

2.3.3.2. Yapısal Kapital

Bu kapital, süreç, yapılar, bilgi sistemleri ve onları oluşturan çalışanlardan ve yöneticilerden bağımsız fikri mülkiyetlerdir. Fikri mülkiyet bazen entelektüel kapitalin dördüncü bileşeninden ayrı olarak kabul edilir [4]. Özümlenmiş, içselleştirilmiş ve şirketin ürün ya da hizmetlerinde yatırıma dönüştürülmüş bilginin değeridir. Bu kapitalin bir bölümü süreçlerdeki bilgi, bir bölümü tescil edilen markalar, ticari haklar, telif-patent haklarıdır. Diğer bir bölümü ise insan kaynakları ile sağlanan, öğrenilen ve somut hale getirilen bilgidir [3].

2.3.3.3. Müşteri Kapitali

Organizasyonun, müşteri sadakati, dağıtım kanalları, markalar, lisanslama ve franchise dâhil olmak üzere müşterileriyle ilişkilerinin değeridir. Müşteriler çoğu zaman bir satış görevlisi veya müşteri temsilcisiyle tahviller oluşturduğundan, müşteri kapitali tipik olarak çalışan ve işverene aittir [4].

Bir firmanın müşterilerinin sayısının, büyüklüğünün, değerinin, o firmada çalıştığı sürenin, firmayla birlikte gerçekleştirdiği işlerin miktarının ve tekrarlanma oranının bir ölçüsü şeklinde hesaplanabilmektedir. Müşterinin sektöründeki yeri ya da büyük firmaların sıralanmasındaki konumu gibi ölçütler de bu kapitalin hesaplanması esnasında dikkate alınmaktadır [3].

2.4. BİLGİ YÖNETİMİ

Öncelikle bilgi yönetimi ve paylaşımının ne olmadığından söz edelim:

- Durumlarından hoşnut olmayan çalışanları ilginç bir felsefi kavram ile oyalama gayreti değildir.
- Gerçeği elde etme yolunda varoluşçu bir arayış değildir.
- Bir bilim veya disiplin değildir.
- Son yılların yönetim modası değildir.
- Bilgi yönetimi bilgi mühendisliği değildir.
- Bilgi yönetimi sadece dijital ağlarla değil süreçle de ilgilidir.
- Bilgi yönetimi tek seferlik bir yatırım ile ilgili değildir.
- Bilgi yönetimi "bilgiyi" yakalamakla ilgili değildir [8], [10], [5].

Bilgi yönetimi en sade şekliyle, bilginin oluşturulması, elde bulundurulması, paylaşılması ve geliştirilmesi için kullanılan yeni radikal araçlar olarak tanımlanabilir. Bu sebeple, bilginin saklanmasını ve bilinçli bir biçimde bir sonraki nesillere aktarılmasını belirten olağan bilgi yönetimini değil, şimdi elimizde olan bütün gelişmiş enformasyon teknolojilerini bilginin oluşturulması, elde bulundurulması, paylaşılması ve geliştirilmesi amacıyla kullanılan tümüyle yeni ve radikal yöntemleri ele almamız gerekmektedir [3].

Bilgi yönetimi bir sistemde enformasyon ve bilginin büyümesini, akmasını ve değer yaratmasını sağlamak için sistematik bir disiplin ve bir dizi yaklaşım olarak tanımlanabilir. Bu, insanları, bilgiyi, iş akışlarını, araçları sağlamayı, en iyi uygulamaları, anlaşmaları ve uygulama topluluklarını içerir.

21. yüzyıl iş dünyası, artan ekonomik ve politik kargaşa, daha hızlı bir inovasyon temposu, ağlar arası bir organizasyon yapısı, entelektüel sermayeye odaklanma ve artan bir çalışan kayıp oranı ile öne çıkmıştır. Bu bağlamda bilgi yönetimi; risk yönetimi, verimliliğin arttırılması, bilginin kalıcılığı ve daha verimli yenilikler için kritik bir disiplin olarak yorumlanmaktadır [11].

Bilgi yönetimi, bir şirketin işi için gerekli olan bilgileri çalışan performansını ve kurumsal rekabetçiliği artıracak şekilde seçen, ayrıştıran, depolayan, organize eden, paketleyen ve ileten, planlı, sistematik bir iş optimizasyon stratejisidir. Bu tanımdan, Bilgi yönetiminin temel olarak fikri varlıkları ve diğer bilgileri şirkete rekabet avantajı sağlayacak şekilde yönetmeye yönelik sistematik bir yaklaşımla ilgili olduğu açık olmalıdır. Bilgi Yönetimi, bir iş optimizasyon stratejisidir ve belirli bir teknoloji veya bilgi kaynağı ile sınırlı değildir. Bu tanımdan, bilgi yönetiminin temel olarak fikri varlıkları ve diğer bilgileri şirkete rekabet avantajı sağlayacak şekilde yönetmeye yönelik sistematik bir yaklaşımla ilgili olduğu açık olmalıdır. Bilgi yönetimi, bir iş optimizasyon stratejisidir ve belirli bir teknoloji veya bilgi kaynağı ile sınırlı değildir. Çoğu durumda, bir bilgi yönetimi girişiminde, yalnızca manuel işlemlerde sağladıkları zaman ve çaba tasarrufu nedeniyle çok çeşitli bilgi teknolojileri önemli bir rol oynar. Bilgi yönetimi süreci, verinin enformasyona dağıtılmasını ve bilginin enformasyonu içermesini içerir. Bu adım daha sonra depolanması gereken veri miktarını netleştirir ve sınırlandırır. Bilgi bir tür bellek sisteminde saklanmadan önce, daha sonra alınmayı kolaylaştıracak şekilde düzenlenmelidir. Organizasyon genellikle bir temsil dili ve kavramları tanımlamak için kullanılan bir kelimeye karar vermeyi içerir [4].

Bir şirkette bir bilgi yönetimi girişiminin uygulanmasındaki en büyük engellerden biri, fikri üst yönetime ve son kullanıcılara satmaktır. Bilgi yönetimi genellikle pahalı bir öneridir; bunu sağlamak için sadece teknoloji altyapısının masrafı değil, aynı zamanda kurum kültürü değişikliklerinin uygulanması ve çalışanın ödül yapılarının canlandırılması ile ilgili masraflar da var. Bilgi yönetimi stratejiniz uygun şekilde planlanmamışsa, kolayca gösterilebilecek acil bir sonuç yoktur ve bu, bütçeyi kontrol eden üst yönetim arasında şüpheciliği daha da artırır [5].

Birçok kuruluş, bilgi paylaşımı ve düzene koyma süreçlerinde gerçek faydalar sağlayan bilgi yönetimi stratejilerini ve altyapısını uygulamaktadır. Şirketler, bilgi yönetiminin faydasını en üst düzeye çıkarmak için daha fazla teknolojiyi kullanmaktadır, ancak bunlardan tam olarak yararlanamadıklarına dair kanıtlar vardır. Bir iş birliği ve bilgi paylaşımı kültürü mevcut değilse, bu teknolojiler asgari fayda sağlayacaktır. Bir kuruluşun başarılı bir bilgi yönetimi uygulaması için teknolojiler uygulamadan önce kültürel meseleleri ele alması gerekir. Bilgi yönetimi araştırmalarının kapsamlı bir incelemesi, bilgi yönetimi teknolojisinin

uygulanmasının önündeki ana engellerden birinin, bilgi paylaşımını teşvik eden bir örgüt kültürünün yokluğu olduğunun altını çizmektedir.

Günümüzün dengesiz ve rekabetçi iş ortamında ilerlemek için kuruluşlar, daha iyi kalitede yeni ürünler ve hizmetler geliştirmeye, pazar gereksinimlerine daha hızlı yanıt vermeyi ve müşteri memnuniyetini arttırmaya çalışırlar. Bu hedeflere ulaşmadaki potansiyel darboğazların yalnızca emek veya sermaye yönetiminde değil aynı zamanda çalışanların bilgilerini etkin bir şekilde yönetme becerisinde de bulunduğu açıkça görülmüştür. Özellikle daha fazla organizasyon, örgütsel sınırlardan ziyade fonksiyonel bağımlılıklarla yönetilen iş ilişkileri ile tanımlandığı için, bilgi yönetimi modern organizasyonlar için büyük bir zorluktur.

Bilginin hızla büyüyen önemi, birçok kuruluşun artık bir örgütsel bilgi deposu inşa ederek çalışanlarının ilgili toplu bilgilerini düzenlemeye ve kullanıma sunmaya çalıştığı gerçeğiyle vurgulanmaktadır. Bilgi havuzlarının geliştirilmesinin nedeni, modern işin temel stratejik varlığını oluşturan bilginin yakın zamanda gerçekleşmesidir. Bununla birlikte, kuruluşlar bildiklerini ayırt etmenin, bilgisinin değerini bilmenin ve kazanma potansiyelini en üst düzeye çıkarmak için bu bilgiyi faydalı ürün ve hizmetlere nasıl dönüştüreceği konusunda belirsiz fikirlere sahiptir. Birçok kuruluş, bilgi varlıklarını verimli ve düşük maliyetli bir şekilde yönetme ile ilgili sorunlara çözüm getiren bilgi yönetimi stratejileri ve altyapıları uygulamaktadır [12].

2.4.1. Bilgi Yönetimi Sistemi ile Veri Ambarı Arasındaki Fark

2.4.1.1. Yönetilen Enformasyon Tipleri

Bir veri ambarının kapsamı özenle ve geniş tutularak yapılandırılır. Bu yapılanma bilgi yönetimi sisteminin destek ihtiyacını resmen ya da gayrı resmi anlamda karşılayabilecek düzeydedir. Yine de veri ambarları, bilgi yönetimi sisteminden gelecek video, ses kayıtları, konuşmalar ve benzeri özel istekleri karşılayamaz. Çünkü bu, veri ambarlarını, bilgi yönetimi sisteminin bir parçası konumuna sokacaktır.

2.4.1.2. Bağlam

Veri ambarları, gerçek verileri araştırıp bulmak isteyenler için bulunmaz birer kaynaktır. Böyle bir veri bulunup yorumlandıktan sonra değer kazanır. Ama yorumlama ihtiyacı bulanık bir fikirdir; veri ambarları kendi başlarına yetersiz bir içeriye sahiptir. Dijital *Knowledge Asset's SceeneServer* gibi bazı ürünler, bağlamın, veri ambarlarına giden veri ile

paketlenmesine belirli ölçüde imkân tanıyorlar; yine de bu bilgi yönetimi sistemlerinin, veri ambarlarından daha büyük bir bağlama ihtiyaç duymasını önleyemiyor.

2.4.1.3. Boyut

Veri ambarlarının birincil ilgi alanı temiz, yapılandırılmış ve organize veriler olduğundan bu depoların boyutlarının her zaman büyük olması gerekir. Burada öncelikle ham veriler depolandığından stok kapasitesinin de çok geniş olması şarttır. Buna karşılık bilgi yönetimi sisteminin depolama kapasitesi çok küçük ile devasa arasında değişen boyutta olabilir. Çok ortamlının kapsamı genişlemeye bağladığında bu kapasitenin de büyümesi kaçınılmaz.

2.4.1.4. İçerik Odağı

Bilgi yönetimi sisteminin içerik odağının en ince süzgeçten geçirilmiş enformasyondan ve bilgilerden oluşması gerekir. Buna karşılık veri ambarları için ham, temiz ve organize edilmiş veriler önemlidir.

2.4.1.5. Başarım

Düzenleme ve sınıflandırmanın karmaşık yapısından dolayı, bilgi yönetimi sisteminin bu karmaşanın üstesinden gelebilmesi şarttır. Bu yüzden de gerek başarımı gerekse bilgi işlem gücünün bir veri ambarınınkinden çok yüksek olması gerekir. Ayrıca, çok ortamlının dijital olması durumunda, işlemciler de grafik çizim ve uygulamalarının getireceği ek yükü kaldıracak kapasitede olmalıdır.

2.4.1.6. İletişim Ağları

Veri ambarlarının işlevlerini yerine getirmeleri için canlı bir iletişim ağı üzerinde bulunmaları gerekmez. Buna karşılık bilgi yönetimi sistemleri için canlı iletişim ağı zorunludur [3].

2.4.2. Bilgi Yönetiminin Temelleri

Bilgi Yönetimini kavrayabilmek amacıyla temel adımlarının ve uygulamadaki temel eylemlerinin neler olduğu incelenecek olursa, dört temel adımdan ve dört temel eylemden söz edilmektedir [3].

2.4.2.1. Bilgi Yönetiminin Temel Adımları

Bilgi yönetimin için dört temel adım aşağıda kısaca açıklanmıştır:

Kavramsallaştırma: Bir organizasyonun sahip olduğu bilgi varlıklarını belirlemesi için bir araştırma ve sınıflandırma çalışmaları yapması, bilginin neleri içerdiğini, nerede ve ne şekilde olduğunu, ulaşılabilirlik derecesini ve yararının neler olduğunu araştırmasıdır.

Yansıtma: Organizasyonun bilgi ile kendisine ne şekilde değer katabileceğini incelemesi, bilgi varlığının kullanılmasında fırsatların neler olduğunu araştırması, bu kullanımın etkisinin ne olacağını incelemesi, bilginin kullanımındaki engellerini belirlemesi ve onun kuruluşa kazandıracağı değer artışını ölçmesi ve değerlendirmesidir.

Eylem planlama: Organizasyonun daha iyi kullanım ve daha çok katma değer sağlaması için gereken aksiyonları belirlemesi, bilgi varlığının kullanımı için eylemleri nasıl planlaması, nasıl başlatması ve nasıl izlemesi gerektiğine karar vermesi, bilgiyi ilişkili etkinliklerle bütünleştirmesidir.

Gözden geçirme: Organizasyonun bilginin katma değer elde etmesi için kullanımlarını incelemesi, bilgiyi kullanmasının istenen katma değeri sağlayıp sağlamadığını ve bilginin yeniden kullanımı için nasıl korunabileceğini belirlemesi ve kullanımın yeni hangi fırsatları oluşturup oluşturmadığını gözlemlemesidir.

2.4.2.2. Bilgi Yönetiminin Temel Eylemleri

Bilgi yönetimi stratejik projesinin uygulanması esnasında gerçekleştirilen temel eylemler burada dört başlık altında anlatılmaktadır.

Bilginin yaratılması: Yaratma eylemi bir bilim değildir, sanattır. İnsanın konularını ve temalarını belirleyebilme şansı olsa da yaratma süreci sonuçlarının yönetilmesi zor bir iştir. Kişi bu aşamada sadece gayret gösterebilir. Gösterilecek çabalardan bazıları; yaratıcı beyinleri bir araya getirerek elverişli şartları sağlamak ve belirli bir sabır göstermek veya bilgiyi dış kaynaktan satın almak için bir yol bulmak. Bilginin dönüşümünün yapıldığı süreçleri cesaretlendirmek en fazla öneme sahip bilgi yaratma yöntemidir.

Çekirdek bilginin ele geçirilmesi: Çekirdek bilgiyi elde etme eylemi, önemli bir yetkinlik ile ilişkili olarak ihtiyaç duyulan bilgi türleri açısından sürekli bilinç artışı olarak

tanımlanmaktadır. Bilginin tamamlanmasında, yerinin belirlenmesinde ve ele geçirilmesini kolay hale getirecek teknik altyapının oluşturulmasında bir yoğunluk vardır. Bilgi yolculuğu, organizasyonun bilgi yönetiminin kendi işi açısından ne kadar değerli olduğunu anlaması ve başarılı birkaç pilot uygulama yapması ile başlar. Bu da giderek daha geniş bir çevrenin ilgisini uyandırır. Bilginin çekirdek unsurlarını ortaya çıkarmak amacıyla gerekli ön filtreler oluşturulur. Ele geçirme, büyük olasılıkla iş başında gerçekleşir.

Bilginin kullanıma sokulması: Bilginin parçalarını genellikle daha sonraki aşamalarda kullanmak amacıyla hazır hale getirilmesi olarak tanımlanır. Güçlü ve gelişmiş teknolojiler sunulmaktadır. Fakat yine de kişiler bu çekirdek bilginin basit ve kullanılabilir durumda olmasına çaba göstermelidir. Ulaşılabilirliğin önünde herhangi bir engel, bir kısıtlama bırakmamak önemli olan şeydir. Bilgiye kuruluşun her alanından her zaman herkes ulaşabilmelidir.

Bilginin topluluklar arası paylaşımı: Kuruluş, uygulama topluluklarının bir araya gelmesi (bir iş ihtiyacı nedeniyle) ve dağılması (iş ihtiyacının ortadan kalkması nedeniyle) için araçlar ve uyarıcı nedenler sağlamalıdır. Bu sebeple, dönemsel ya da tek seferlik projeler olduğu kadar açık uçlu, sürüp giden projeler de olmalıdır. Uygulama toplulukları takımlar ile aynı değildir. Takımlar aynı bir hedef veya şirket amacının peşinde giderken uygulama toplulukları ortak bir menfaat çevresinde toplanırlar. Bu ayrım önemli değildir. Bunun nedeni, bilgi paylaşımının sadece takımların içlerinde değil, takımların aralarında da bulunmalarını cesaretlendirmesi gerekir [3].

2.5. BİLGİ YÖNETİMİ PRENSİPLERİ

Lehaney tarafından tanımlanan bilgi yönetim prensipleri [13]:

- Bilgi yönetimi pahalıdır.
- Bilginin etkili yönetimi insan ve teknolojiyi içeren melez çözümler gerektirmektedir.
- Bilgi yönetimi yüksek seviyede politiktir.
- Bilgi yönetimi bilgi yöneticilerini gerektirmektedir.
- Bilgi yönetimi modellerden, haritalardan ve hiyerarşilerden ziyade pazarlardan daha çok fayda sağlar.
- Bilginin kullanımı ve paylaşımı genelde doğal olmayan davranışlardır.

- Bilgi yönetimi bilgi süreçlerinin gelişmesidir.
- Bilgiye giriş sadece bir başlangıçtır.
- Bilgi yönetimi hiçbir zaman bitmez.
- Bilgi yönetimi bilgi sözleşmesine ihtiyaç duyar.

2.6. BİLGİ DÜZEYLERİ

2.6.1. Care-Why (Bilgiyi Niçin Koruyalım)

Care-Why, şirketin içinde var olan öz-motivasyonu simgeler. Bu derece bilgi yönetiminden destek alamayacak tek derecedir. *Care-Why* motivasyonu yüksek ve enerjik küçük şirketlerin, çok daha fazla para ve kaynaklara dayanan büyük şirketleri nasıl yenebileceğini açıklar. Bu bilgi düzeyi şirketin yapısal kültüründen kaynaklanır. Bu nedenle de diğer üç dereceye teknolojik destek verirken, buna da en üst düzey de teknoloji dışı destekler sağlamamız gerekir. Örneğin inançlar bu kategori de yer almaktadır.

2.6.2. Know-Why (Niçin Bilgi)

Bilginin *know-why* yönünü sistemin anlayışı simgeler. Bu, işverenin sorumlulukları zincirine giren ve sebep-sonuç ilişkisinin karmaşık yapısına yönelik derin bir bilgi türüdür. *Know-why,* çalışanların bilinmeyen içsel çatışmalar ve görünmeyen durumlar karşısında nasıl davranacaklarını göstererek onların bir üst dereceye, yani *know-how*'a yükselecek becerilerle donanmasını sağlar. Örneğin bir borsacının ne zaman almak, ne zaman satmak gerektiğini sezgisel olarak bilmesi ya da bir futbolcunun havadan gelen topu nerede durdurabileceğini sezmesi bu tür bilgidir.

Çoğu şirket bu derecenin bir altı olan *know-how* aşamasındadır. *Know-how*'da bilinen kurallar uygulanmakta ve bu da onlara kolaylık sağlamaktadır. Ne var ki bilgi ekonomisi bundan fazla beceri istemektedir. Bu yüzden de bilgili işçiler düzeyine erişilmesi için bilgi yönetiminin desteğine kesin ihtiyaç duyulacaktır.

Beyin fırtınalarının yaşanacağı toplantılar düzenlenir, fikir alışverişlerine gidilir. Gene de, kendi bilgi düzeylerim göz önünde tutan çoğu şirket bu türden toplantılar düzenlemez.

2.6.3. Know-How (Var Olan Bilgi Birikimi)

Know-How, kitabi olarak bilinen bir işin, hayata nasıl geçirilebileceği bilgisidir. Örneğin, şirketlerin pazarlama bölümleri, çok pahalı bir reklamın satışı ne kadar yükselteceğini çok iyi bilirler. Bu sebeple, rekabet koşulları altında dayanabilmek için *know-how*'un teknoloji-kökenli çerçevesinden *know-why*'a geçiş yapmaları gerektiğini de bilirler. Profesyonel *know-how*, çalışanlara gerçek dünyanın karmaşık sorunlarının sürekli yinelenmesi, gösterim ve sunumlar yapılması ile düzenli bir yükseliş içine girer. Bu sebeple de herhangi bir network sistemi ve bilgi destek sistemleri yardımı almaları gerekir.

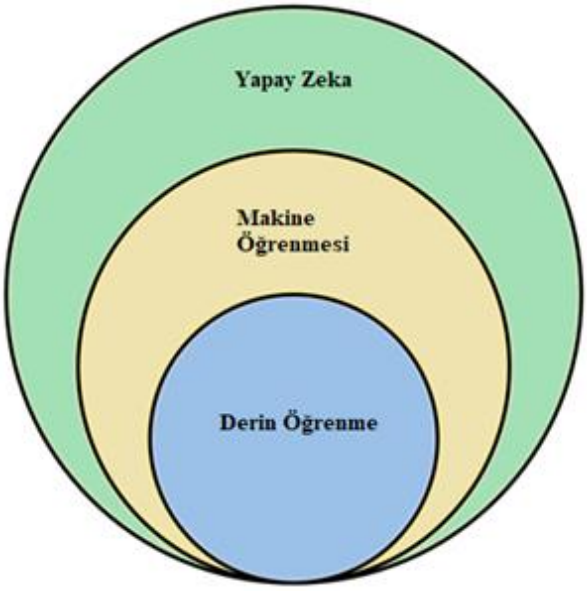
2.6.4. Know-What (Ne için Bilgi)

Temel bilgilerdir. Rekabetin gerekli ama yetersiz derecesidir. Kolej mezunu bir gencin kolaylıkla ulaşabileceği bilgi düzeyidir. Okulda ne yapacağını öğrenmiş ama henüz hayata geçilmemiş olduğu bilgileri uygulamayı bu aşamada öğrenir [5].

2.7. DERİN ÖĞRENME (DEEP LEARNING)

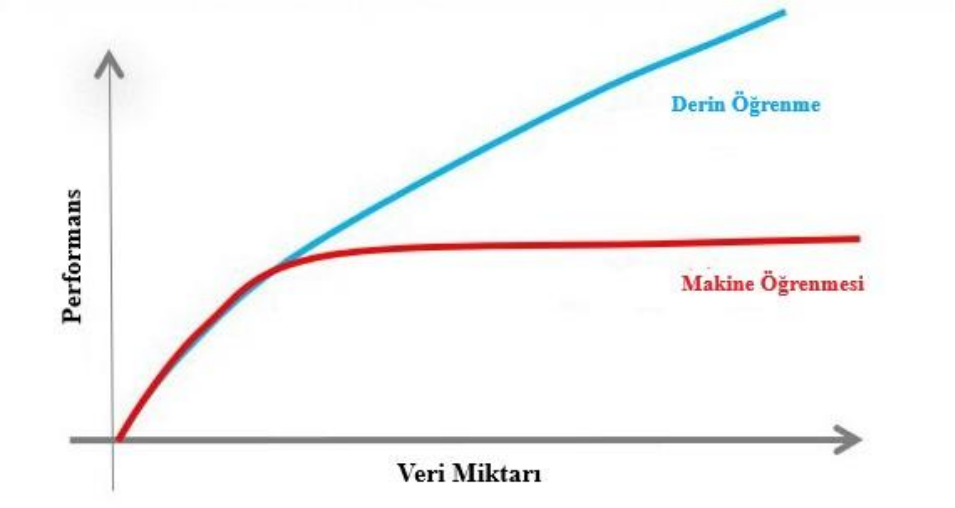
Derin öğrenme (Deep Learning) için literatürde farklı birçok tanım yapılmıştır. Derin öğrenmeyi tanımlamak ve derin öğrenme ile diğer makine öğrenmesi yaklaşımları arasındaki farkı anlamak için önce makine öğrenmesi hakkında biraz fikre sahip olmak gerekir. Makine öğrenmesi, eğitim örneklerinden örüntüleri tanımlama ve bu öğrenilen örüntüleri yeni görünmeyen verilere uygulama görevidir. Makine öğrenmesi ayrıca bazen tek katmanlı gösterimleri öğrenme doğası nedeniyle derin olmayan öğrenme olarak da adlandırılır [14].

Yapay zekâ normalde insanlar tarafından gerçekleştirilen düşünme ile ilgili görevleri otomatikleştirme çabasıdır. Bu nedenle, yapay zekâ, makine öğrenme ve derin öğrenmeyi kapsayan genel bir alandır, ancak aynı zamanda herhangi bir öğrenmeyi içermeyen daha birçok yaklaşımı da içerir. Yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişki şekildeki gibi görselleştirilebilir [14], [15]:



Şekil 2.1: Derin Öğrenme, Makine Öğrenmesi ve Yapay Zekâ Arasındaki İlişki [14].

Derin öğrenme bir makine öğrenmesi türüdür. Veri miktarı arttıkça, makine öğrenme teknikleri performans açısından yetersiz kalmıştır ve derin öğrenme doğruluk gibi ölçütlerde daha iyi performans vermektedir. Derin öğrenmenin makine öğrenmesinden farkı; makine öğrenmesinde özellikler manuel olarak verilir fakat derin öğrenme bu özellikleri veriden doğrudan öğrenir [16].



Şekil 2.2: Makine Öğrenmesi ve Derin Öğrenme Arasındaki Performans Farkı [16].

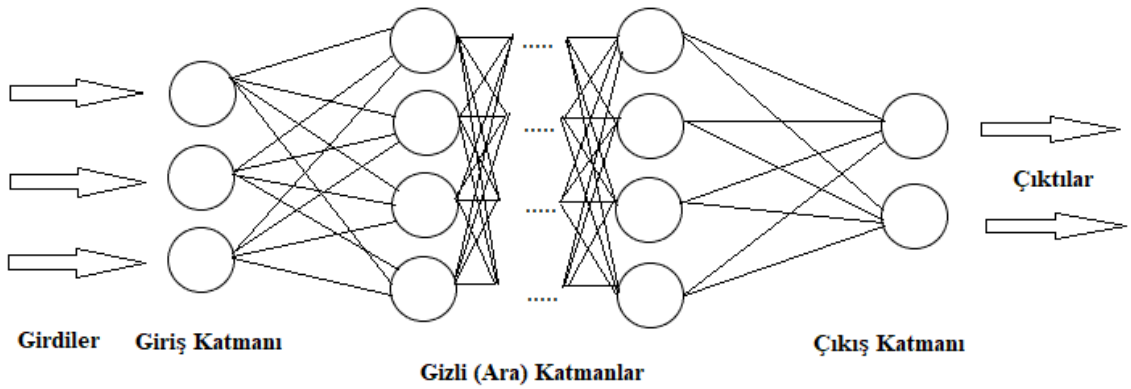
Son yıllarda verinin çok fazla artış göstermesiyle makine öğrenmesi teknikleri iyi sonuçlar vermemeye başlamıştır. Örneğin 1 milyonluk bir veri için makine öğrenmesi kullanıldığında derin öğrenmeden daha düşük bir doğruluk elde edilmektedir. Bu nedenle makine öğrenmesi teknikleri yetersiz kalmıştır. Bunun yanı derin öğrenme teknikleri veri sayısı sadece çok yüksek olduğunda kullanılmaktadır diye bir şart olmadığından az miktarda verilerde de kullanılabilmektedir.

Derin öğrenme, 1940'lardan bu yana var olan yapay sinir ağlarından gelişmiştir [17]. Yapay sinir ağları, beynin yapısından ve işlevinden ilham alan algoritmalarla ilgili bir makine öğrenmesi alt alanıdır. Bilgisayar bilimlerinin alt disiplini olarak görülen yapay zekânın alt kolu olan yapay sinir ağı sinir hücresi olarak da adlandırılan nöronlardan ilham almaktadır.

Dentrit adı verilen sinir hücreleri sensörlerden sinyalleri alır ve bu sinyaller *nöronlar* vasıtasıyla ateşlenmektedirler. *Axon* olarak adlandırılan iletim kanalları yardımıyla başka sinir hücrelerine iletilen bu sinyaller sinir hücreleri ile yönlendirilmektedir. Diğer bir deyişle *nöron* ve *nörvlere* taşınan bu sinyaller *axonlar* vasıtasıyla taşınmaktadır. Bilgisayarlara adapte edebilmesi bakımından sinyallerin analog olması, sinyallerin iletilmesi esnasında yaşanan bir problemdir. Elbette ki bir insanın vücudu 0 ve 1'lerden oluşan ikililer (binary) ile çalışmaz, buna karşılık insan vücudu sürekli olan sinyaller kullanmaktadır. Bu hücrelerin giriş ve çıkış sinyallerini taşıyan parçaları olan *sinapsisler,* sinir hücreleri ile alakalı bilmemiz gereken başka bir konudur. Bunlar program ile yapay sinir ağı arasındaki ara yüz görevi görmektedir. Bir sinyali iletmek ya da iletmemek bir karar mekanizmasıdır. Bu karar mekanizması çok seviyeli düşünülebilir [18].

Derin öğrenme, modelin sınıflandırma görevlerini doğrudan görüntülerden, metinden veya sesten yapmayı öğrendiği bir makine öğrenmesi türüdür. Derin öğrenme genellikle bir sinir ağı mimarisi kullanılarak uygulanır. Derin terimi ağdaki katman sayısını ifade etmektedir. Katman sayısı arttırıldıkça ağın yapısı daha da derinleşmektedir. Klasik yapay sinir ağları yalnızca iki ya da üç katmandan oluşabilirken; derin ağlar yüzlerce katmandan oluşabilmektedir. Derin öğrenme, özellikle yüz tanıma, metin çevirme, ses tanıma ve şerit sınıflandırma ile trafik işareti tanıma dâhil olmak üzere gelişmiş sürücü destek sistemleri gibi tanımlama uygulamaları için çok uygundur.

Derin bir sinir ağı, paralel olarak çalışan ve biyolojik sinir sistemlerinden ilham alan basit elemanlar kullanarak çoklu doğrusal olmayan işlem katmanlarını birleştirir. Bir girdi (giriş) katmanı, birkaç gizli katman ve bir çıktı (çıkış) katmanından oluşur. Katmanlar, giriş olarak önceki katmanın çıktısını kullanan her gizli katman ile düğümler veya nöronlar aracılığıyla birbirine bağlanır [19].



Şekil 2.3: Derin Sinir Ağlarının Genel Yapısı [19].

Derin öğrenme, makine öğrenmenin özel bir şeklidir. Bir makine öğrenme iş akışı, alakalı özelliklerin görüntülerden manuel olarak çıkarılmasıyla başlar. Özellikler daha sonra görüntüdeki nesneleri kategorilere ayıran bir model oluşturmak için kullanılır. Derin öğrenme iş akışıyla, alakalı özellikler görüntülerden otomatik olarak çıkarılır. Ek olarak, derin öğrenme "uçtan uca öğrenmeyi" gerçekleştirir; burada bir ağa ham veriler ve sınıflandırma gibi gerçekleştirmesi gereken bir iş verilir ve bunun otomatik olarak nasıl yapıldığını öğrenir [20].

2.8. DERİN ÖĞRENMENİN TARİHÇESİ

Yapay sinir ağları ve insan beyninin fonksiyonlarını taklit etmeye yarayan hesaplama sistemleri kavramına dayanan derin öğrenmenin tarihi 1943 yıllarına dayanmaktadır. Walter Pitts ve Warren McCulloch [21], 1943'te düşünce sürecini taklit etmesi amacıyla matematiğe ve sinir mantığı adı verilen algoritmalara dayalı sinir ağları için bir hesaplama modeli oluşturmuşlardır.

Ivakhnenko ve Lapa [22], 1965 yılında, derin öğrenme yöntemlerini geliştirmek için "Sibernetik Tahmin Araçları" adlı çalışmalarında kullandıkları modeller, karmaşık denklemlerin aktivasyon fonksiyonlarına sahip modeller olmuştur.

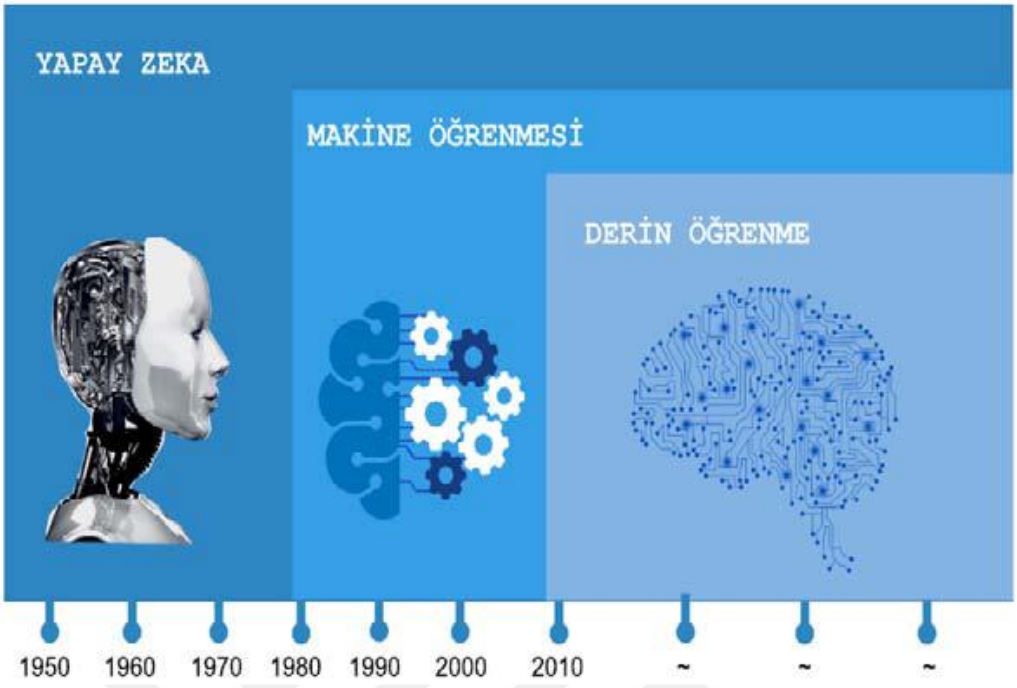
1980'li yıllarda Fukushima [23], el yazısı tanıma gibi desen tanıma problemleri için kullandığı çok katmanlı yapay sinir ağı olan Neocognitron'u önermiştir. Bilgisayarın öğrenmesi için görsel örüntüleri önerdiği tasarımda kullanmıştır.

1992 yılında Weng ve arkadaşları [24], yayımladığı "Cresceptron" yöntemi karma sahnelerden otomatik olarak üç boyutlu nesne tanıma işlemini gerçekleştirmiştir. 1995'te Vapnik ve Cortes [25], geliştirdikleri destek vektör ağları ile birbirleriyle benzer olan verilere sahip iki grubu sınıflandırmışlardır. 1997'de Schmidhuber ve Hochreiter [26], önerdikleri tekrarlayan sinir ağı ile LSTM uzun süreli bağımlılık sorunlarını çözmüşlerdir.

Hinton ve Salakhutdinov [27], 2006 yılındaki çalışmalarından sonra derin öğrenme yöntemleri popüler olmaya başlamıştır. Aynı zamanda çok katmanlı bir sinir ağındaki bir katmanın tek seferde önceden nasıl eğitebileceğini göstermişlerdir. 16000 işlemciden ve bir milyarı aşan miktarda bağlantıdan oluşan yapay örüntü tanıma yöntemlerinin performansının insan seviyesine ulaşması ise 2012 yılında Google ekibi tarafından gerçekleştirilmiştir.

2014'te için DeepFace isimli derin öğrenme teknolojisini kullanan Facebook, bu teknoloji sayesinde fotoğraflarda kullanıcılarının otomatik olarak etiketlenmesini sağlamıştır. "AlphaGo" olarak adlandırılan Google'ın *DeepMind* algoritması 2016'da, karmaşık tahta oyunu *Go* sanatında, milyonlarca simülasyon kullanarak uzmanlaşması ile bu algoritmaya profesyonel bir oyuncu olan Lee Sedol turnuvada 4-1 yenilmiştir.

Yapay zekâ teknolojisi 1940'lı yıllarda başlamıştır ve onun bir alt dalı olan makine öğrenmesi 1980'li yılların başında yapay zekânın yerini almıştır. 2010 yılının başlarında ise makine öğrenmesinin yetersizliği derin öğrenme ile giderilmiştir. Teknolojinin ilerlemesiyle öğrenme yöntemlerinin tarihsel değişimi Şekil 2.4'te gösterilmektedir [28].



Şekil 2.4: Derin Öğrenme, Makine Öğrenmesi ve Yapay Zekânın Tarihsel Değişimi [28].

2.9. DERİN ÖĞRENME SÜRECİ

Derin öğrenmede süreç, sonuçtaki başarım oranı belli bir düzeye gelinceye kadar tekrar etmektedir. Aşağıda belirtilen adımlar bu süreçte sırasıyla yapılmalıdır [28]:

- Problemin tanımı yapılır ve derin öğrenmeye uygunluğu tespit edilir.
- İlgili veri kümesi tanımlanır ve analiz için hazırlanır.
- Uygulanacak derin öğrenme algoritması seçilir.
- Tanımlı veriler ile kullanılan algoritma eğitilir.
- Eğitilen modelin performansı tanımsız veriler ile test edilir.

2.10. DERİN ÖĞRENME MİMARİLERİ

2.10.1. Evrişimli Sinir Ağları

Konvolüsyonel Sinir Ağları (Convolutional Neural Networks) olarak da geçen veya CNN'ler olarak da bilinen evrişimli ağlar, bir ızgara benzeri topolojiye sahip verilerin işlenmesi için uzmanlaşmış bir tür sinir ağıdır. Evrişimli ağların tarihi, ilgili sayısal modeller geliştirilmeden

çok önce olan sinirbilim deneyleri ile başlar. Nörofizyolog olan David Hubel ve Torsten Wiesel'in [29, 30, 31], birkaç yıl süren memelilerin görme sisteminin nasıl çalıştığı hakkındaki çalışmaları bu derin öğrenme modellerinin en temelini oluşturmaktadır. Çağdaş derin öğrenme modelleri üzerinde en fazla etkiye sahip olan bulguları, kedilerde bireysel nöronların aktivitesini kaydetmeye dayanmaktadır. Bu iki nörofizyolog, kedinin beynindeki nöronların, kedinin önündeki bir ekranda kesin konumlarda yansıtılan görüntülere nasıl tepki verdiğini gözlemlemiştir. En büyük keşifleri, erken görsel sistemdeki nöronların, kesin olarak yönlendirilmiş çubuklar gibi çok spesifik ışık modellerine en güçlü tepkiyi vermesi, ancak diğer desenlere neredeyse hiç tepki vermemesi olmuştur [32].

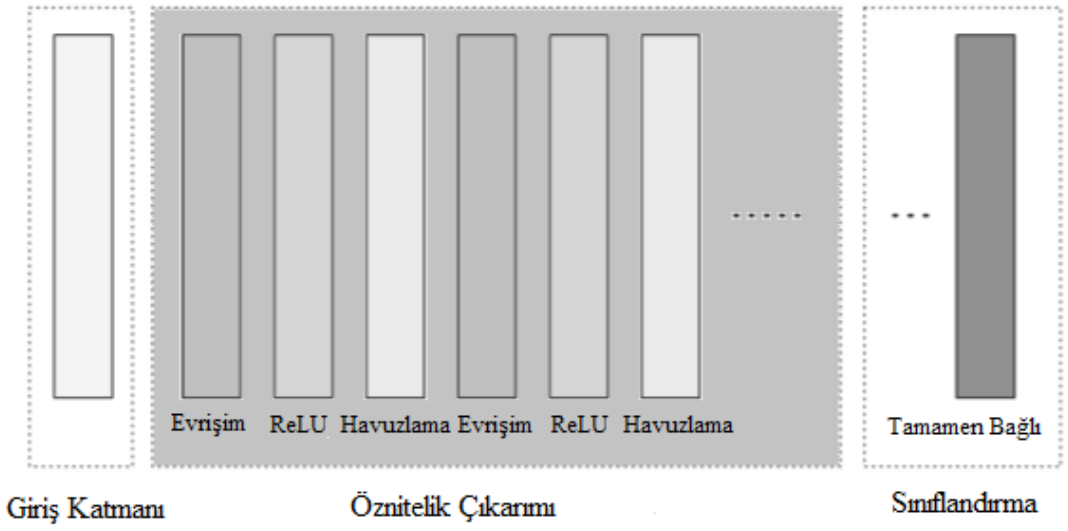
Evrişimli sinir ağı, canlı varlıkların doğal görsel algılama mekanizmasından esinlenilen, iyi bilinen bir derin öğrenme mimarisidir [33].

Bir CNN derin öğrenme için en popüler algoritmalardan biridir; resim, video, metin veya sesten sınıflandırma görevlerini gerçekleştirmeyi doğrudan veriden öğrendiği bir makine öğrenmesi türüdür [34].

CNN'ler, biyolojik olarak esinlenilmiş ileri beslemeli ağların bir türevini temsil eder; burada nöronlar arasındaki bağlantı, giriş verilerindeki bozulma ya da değişmeye yönelik desenlerin değişmezliğini yakalama eğilimindedir. CNN mimarileri genellikle ağların girdisi olarak iki boyutlu verilerle (tipik olarak görüntüler) çalışmayı varsaymaktadır. Üç ana katman tipi kullanılır: *Evrişim (Convolution) Katmanları, Havuzlama (Pooling) Katmanları ve Tamamen Bağlı Katmanlar* [35], [36].

Genel bir CNN mimarisi, evrişim katmanı, havuzlama katmanı, aktivasyon katmanı, normalizasyon katmanı ve tamamen bağlı katmanlar gibi çeşitli katmanlardan oluşur. Evrişim katmanı, havuzlama ve normalizasyon katmanları, ağı oluşturmak için sıralı bir şekilde gömülür. Evrişim ve havuzlama işlemlerinin yapılması, sınıflandırmanın gerçekleştirildiği üst düzey özellikleri art arda oluşturur. Sınıflandırma, CNN mimarisinin tamamen bağlı katmanında gerçekleştirilir. CNN mimarisinde, CNN'nin eğitimi sırasında ayarlanması gereken çok sayıda parametre vardır. CNN'lerin eğitimi genellikle geleneksel geri yayılım algoritması ile yapılır [37].

CNN'ler, giriş katmanındaki tüm bağlı katmanlar içindeki girdi verilerini çıktı katmanları tarafından verilen bir sınıf puanlarına dönüştürür. CNN mimarisinin birçok çeşidi vardır, ancak bunlar Şekil 2.5'te gösterildiği gibi katmanların modeline dayanmaktadır [38].



Şekil 2.5: Genel CNN Mimarisi [38].

Geleneksel derin sinir ağlarında, bir sonraki katmandaki tüm nöronlara bir nöron bağlanır. CNN'ler sıradan sinir ağından farklıdır, çünkü evrişim katmanındaki nöronlar, sadece göreceli konumlarına bağlı olarak bir sonraki katmandaki nöronlara nadiren bağlanırlar [39].

CNN'ler, kendi kendini süren otomobiller, robotikler, dronlar ve görme engellilerde tedaviler için belirgin uygulamalara sahip olan makine vizyonundaki büyük ilerlemeleri güçlendirmektedir [38].

CNN'ler temel olarak, aynı nöronun birçok özdeş kopyasını kullanan bir tür sinir ağı olarak düşünülebilir. Aynı nöronun birden fazla kopyasına sahip olmanın hilesi, matematik ve bilgisayar bilimlerindeki işlevlerin soyutlanmasına kabaca benzemektedir. Programlama yaparken, bir fonksiyon bir kez yazılır ve birçok yerde kullanılır. Böylece aynı kodu farklı yerlerde yüzlerce kez yazmamak programı hızlandırır ve daha az hatayla sonuçlanır. Benzer şekilde, evrişimli bir sinir ağı, bir nöronu bir kez öğrenip birçok yerde kullanabilir, bu da modeli öğrenmeyi ve hatayı azaltmayı kolaylaştırır [40].

CNN'i eğitme süreçlerinde bu sinir ağına etiketli binlerce resim verilip hangi görüntü olduğu öğretilmektedir. Bu sinir ağlarında test verisiyle derin öğrenme yönteminin öğrenme işlemindeki başarı oranı hesaplanmaktadır. Sağlık alanında hastalıkların belirlenmesinde, görüntünün işlenmesinde, sesin işlenmesinde, metin ve videonun işlenmesinde, resimlerden başlık oluşturulmasında, resimlerde olan nesnelerin tanımlanmasında bu ağlar oldukça yaygın kullanılmaktadır [28].

Evrişim katmanları, CNN mimarilerinin temel yapı taşları olarak kabul edilir. Evrişim filtresi, bir özellik haritası üretmek için girdi verisine uygulanır [41].

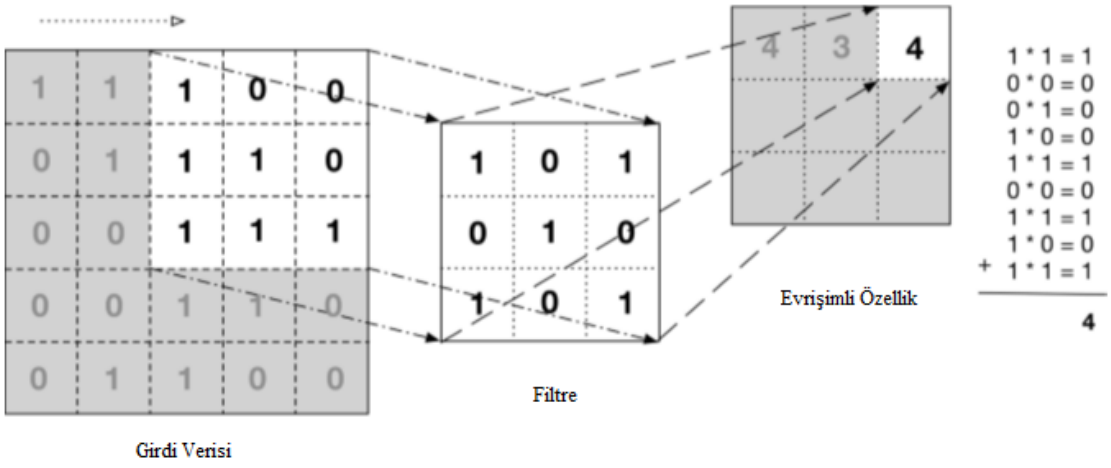
Bir önceki katmandan gelen girdiler üzerinde belirlenen filtreler uygulanarak yeni özellik kümeleri çıkarılmaya çalışılır. Filtre boyutları farklılık gösterebilir (2x2, 3x3, 5x5 vb.). Her bir filtre belirlenen boyutta matrisler ile temsil edilir. Girdi üzerine uygulanan her filtre farklı bir özelliği ortaya çıkarmaya çalışır. Bu noktada girdiler üzerine uygulanacak filtrelerin nasıl seçileceği ve boyutlarının ne olacağı çok önemli bir husustur. Çok büyük boyutlarda seçilen filtreler girdi üzerinde bazı özelliklerin gözden kaçırılmasına neden olabilir. Aynı zamanda filtreler için belirlenen katsayılar, değerler doğru bir şekilde seçilmeli ve güncellenmelidir. Filtrelerin katsayıları, yapay sinir ağlarında bulunan ağırlıkları temsil eder. Her bir yineleme sonucunda bu filtre katsayıları öğrenilir. Öğrenilen değerlere göre bu filtre katsayıları güncellenerek yeni filtreler elde edilir. Evrişim katmanında önemli olan bazı kavramlar şunlardır [42]:

- *Filtre boyutu:* Girdi üzerine uygulanacak filtrenin yükseklik ve genişlik değerlerini ifade eder. Genelde kare matris olarak seçilir.
- *Adım Değeri (Stride):* Filtre matrisinin, girdi üzerinde dolaşırken kaç adım kaydırılacağını belirler.
- *Dış Boşluk Sayısı (Padding):* Bu değer filtre matrisinin dışına eklenecek olan 0'lardan oluşan değer sayısını belirtir. Örneğin: *3x3* boyutunda bir filtreye *padding = 1* uygulanırsa filtrenin yeni boyutu *5x5* olur. Bu özellik girdi boyutu ile çıktı boyutunun aynı kalmasının istendiği durumlarda kullanılır.
- *Çıktı Boyutu (Output Depth):* Girdi üzerine filtreler uygulandıktan sonra elde edilmesi istenen çıktı sayısını temsil eder.
- *Kanal Sayısı:* Girdi ve filtrelerin kaç kanaldan oluştuğunu belirtir. Girdinin kanal sayısı ile girdiye uygulanacak olan filtrelerin kanal sayısı birbirine eşit olmalıdır.

Örneğin: Girdi, *28x28x3* boyutunda ise yani 3 kanala sahip ise filtre de *?x?x3* boyutunda olmalıdır (?: seçeneğe bağlı değerleri temsil eder, 3x3, 5x5 vb.).

Bir evrişim, iki bilgi kümesinin nasıl birleştirileceğine ilişkin bir kuralı tanımlayan matematiksel bir işlem olarak tanımlanır. Hem fizik hem de matematikte önemlidir ve *Fourier* dönüşümlerini kullanarak uzay / zaman alanı ile frekans alanı arasında bir köprü tanımlar. Girdi alır, bir evrişim filtresi uygular ve çıktı olarak bir özellik haritası verir.

Şekil 2.6'da gösterilen evrişim işlemi, bir CNN'nin özellik detektörü olarak bilinir. Bir evrişime gelen girdi veya başka bir evrişimden elde edilen özellik haritası olabilir. Genellikle, filtre (kernel) belirli türden bilgiler için girdi verilerini filtrelediği bir filtre olarak yorumlanır; örneğin, bir kenar filtresi yalnızca görüntünün kenarından gelen bilgilerden geçmeye izin verir. Evrişim işleminde yeni çıktı verileri noktasal çarpım ve toplama işlemleri ile elde edilir.



Şekil 2.6: Evrişim İşlemi [38].

Şekil, iç içe geçmiş özellik (çıktı) verilerini üretmek için filtrenin girdi verileri boyunca nasıl kaydırıldığını gösterir. Her adımda, filtre, çıktı özellik haritasında tek bir girdi verisi oluşturarak, sınırları içindeki girdi verisi değerleri ile çarpılır. Uygulamada, aranılan özellik girdide algılanırsa çıktı büyüktür [38].

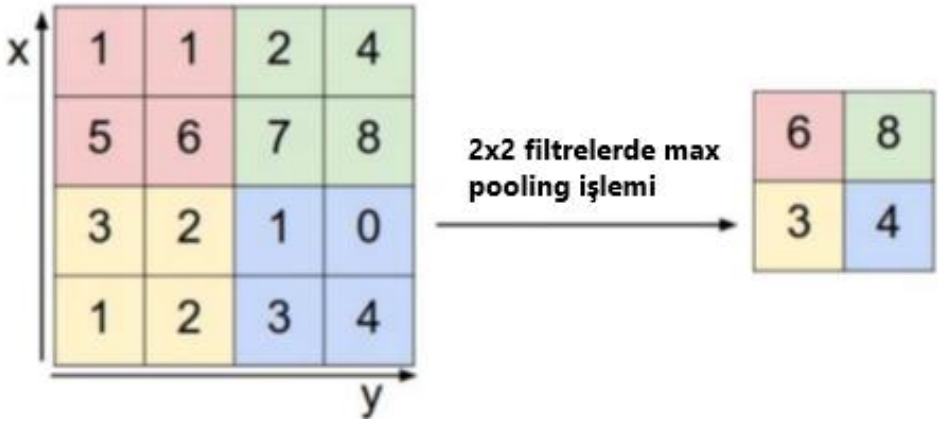
Matematiksel olarak evrişim işlemi aşağıdaki denklemde tanımlanmıştır:

$$a(t) = (x * w)(t) = \int_{-\infty}^{\infty} x(b)w(t-b)db \quad (2.1)$$

Burada x girdi verisi, w filtre ve a özellik haritasıdır. (*) operatörü noktasal çarpımı ifade etmektedir [43].

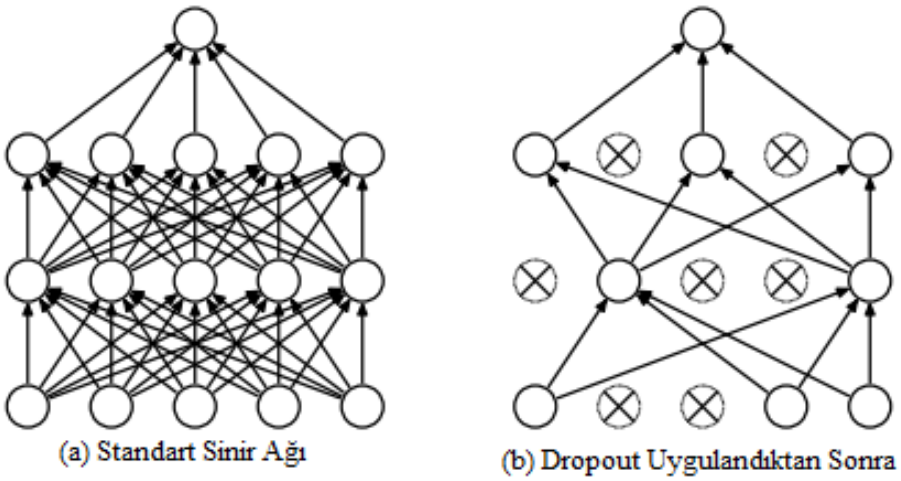
Aktivasyon katmanı, aktivasyon fonksiyonlarının kullanıldığı katmandır. Bir nöronda toplanan tüm girdi değerleri birleştirilip, aktivasyon fonksiyonuna gönderilir. Aktivasyon fonksiyonu girdi miktarına göre bir sonraki katmana aktarılacak olan çıktı miktarını belirler. Çıktı değerleri, 0 ile 1 arasında veya -1 ile 1 arasında eğerler alır [44]. Burada aktivasyon fonksiyonu olarak çoğunlukla *ReLU* (doğrultulmuş lineer birim) kullanılır. Bunun sebebi *ReLU* hem ileri besleme hem de geri yayılma için diğer yaygın aktivasyon fonksiyonlarından daha hızlı çıktılar üretmesidir [45]. Bu katmanda kullanılacak olan pek çok aktivasyon fonksiyonu vardır. Bunlardan bazıları *softmax, sofplus, sigmoid, tanh, linear* ve *exponential* fonksiyonlarıdır.

Havuzlama (pooling) katmanları, genellikle art arda evrişim katmanları arasına yerleştirilir. Bu katman girdi verisi olarak verilen resmin alt örnekleme işlevini yapmaktadır. Havuzlama işlemi CNN'lerde özellik boyutunu düşürmek için kullanılır. Girdi, havuzlama işlemine tabi tutulduğunda belirli bir matematiksel formüle göre yükseklik ve genişlik değerleri azalır. Yükseklik ve genişlik değerlerinin düşürülmesi özellik kaybına neden olsa da sinir ağının eğitilmesini hızlandırır. Havuzlama işlemi kanal (channel) sayısından bağımsızdır. Diğer bir deyişle havuzlama katmanında kanal sayısı, uygulanan girdi ile aynı olmak zorundadır [42]. Havuzlama katmanı, girdi verilerini uzaysal olarak (genişlik, yükseklik) yeniden boyutlandırmak için *max()* işlemini kullanır. Bu işleme maksimum havuzlama denir. *2×2* filtre boyutunda, *max()* işlemi filtre alanındaki dört sayının en büyüğünü alır. Bu işlem derinlik boyutunu etkilemez [38]. Maksimum havuzlamada, bir yerin maksimum piksel yoğunluğu o yerin temsilcisi olarak alınır. Ortalama havuzlamada, bir bölgenin etrafındaki piksel yoğunluklarının ortalaması, o bölgenin temsilcisi olarak kabul edilir [17]. Şekil 2.7'de *2x2* boyutuna sahip filtreler için *max pooling* (filtrelerde oluşan değerlerin en yükseğinin alınması) yapılmıştır. Bu işlemin sonucunda sabit boyuta sahip bir matris oluşur ve çıktı boyutu önemli düzeyde düşürülür [46].



Şekil 2.7: Max Pooling İşlemi [46].

Seyreltme (Dropout) katmanı, öğrenimi gerçekleştirilmiş bir ağda aşırı öğrenmeyi yani ezberlemeyi ortadan kaldırmak için kullanılan bir katmandır. Sinir ağı içerisinde aşırı öğrenmeyi oluşturan bazı bağlantıları ortadan kaldırma işlemini yapar. Böylelikle ağın ezber yapması engellenir. Ağın performansını artırır. Şekilde normal bir yapay sinir ağı bağlantıları ve seyreltme uygulanmış ağ yapısı görülmektedir [47]. Seyreltme değeri için genellikle 0,5 oranı kullanılmaktadır. Probleme ve veri setine göre değişiklik göstermekle birlikte farklı kullanıldığı durumlar da yaygındır. Şekil 2.8'de görüldüğü üzere sinir ağında nöronlar önceki katmanlarla birbirine tam bağlıyken seyreltme uygulandıktan sonra bazı düğümler rastgele kaldırılmıştır [48].



Şekil 2.8: Sinir Ağına Dropout (Seyreltme) Uygulanması [48].

Tamamen bağlı katman, CNN'lerin son katmanlarını oluşturur. Tamamen bağlı katmana gelene kadar olan katmanlarda girdiler için özellik çıkarımı, boyut düşürme ve normalizasyon işlemleri gerçekleştirilir. Elde edilen özellikler sonucunda artık bir tahmin işleminin gerçekleştirilmelidir. Tamamen bağlı katman kendinden önce gelen diğer katmanlarla tamamen bağlıdır. Bundan sonra kullanılacak olan yapı çıkartılan özelliklerin ağırlıklandırılması ve bir çıktının tahmin edilmesi işlemini gerçekleştirir. Elde edilen hata değerine göre ağırlıklar tekrar güncellenecek ve bu çevrim istenen yakınsama değeri elde edilene ya da belirli bir adım sayısı tamamlanana kadar devam eder. Tamamen bağlı katmanının yapısı, yapay sinir ağlarının yapısı ile benzerlik göstermektedir [42].

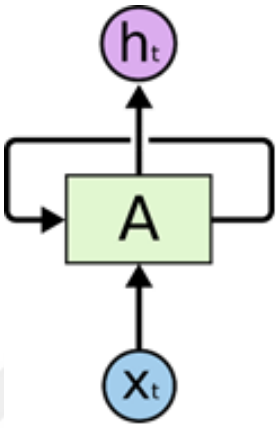
2.10.2. Tekrarlayan Sinir Ağları

Tekrarlayan Sinir Ağları (Recurrent Neural Network, RNN), sıralı verileri işlemek için kullanılan bir sinir ağları ailesidir [32]. Tekrarlayan Sinir Ağları, her vektörü bir giriş vektörleri dizisinden alır ve her seferinde bir tane modeller. Bu, ağın her girdi vektörünü girdi vektörleri penceresi boyunca modellerken ağın durumunu korumasını sağlar. Zaman boyutunun modellenmesi, tekrarlayan sinir ağlarının bir özelliğidir [38].

RNN'ler bilginin devam etmesini sağlayan, içlerinde döngüler bulunan ağlardır. RNN'lerin kendi giriş belleklerini, girdileri işlemek için kullanabilmeleri bu ağları ileri beslemeli sinir ağlarından ayırmaktadır. İnsanlar, yeni öğrendikleri bir sözcük için yeni anlamlar öğrenmezler. Daha önceden var olan benzer sözcüklerden yola çıkarak yeni öğrendikleri sözcüğe anlam yüklerler. Ancak geleneksel yapay sinir ağlarında insanlarda bulunan bu anlamlandırma özniteliği bulunmaz ve bu onların en büyük eksikliğidir. Örneğin, videodaki tüm karelere bakarak aktiviteler sınıflandırmak istendiğinde, geleneksel sinir ağları kareler arasında insanlar gibi anlamlandırma kuramadığından, sınıflandırma yapamayacaktır. Tekrarlayan yapay sinir ağları ise bir döngü oluşturarak, geçmiş bilgilerin kullanılmasını sağlayacak ve böylelikle kareler arasında anlamlandırma yaparak sınıflandırma yapabilecektir. Şekilde döngü gösterilmektedir [49].

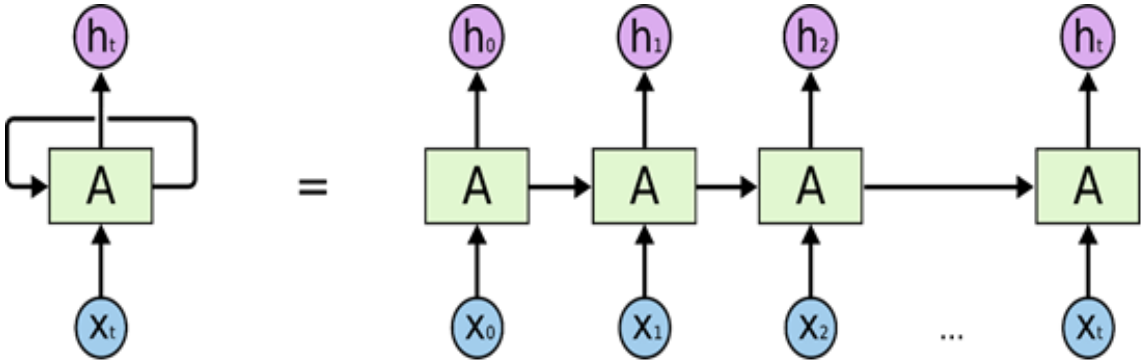
Şekil 2.9'da basit bir tekrarlayan sinir ağı gösterilmektedir. Burada "A" ismi verilen dikdörtgen, bir yapay sinir ağındaki hücreyi temsil etmektedir. Yapay sinir ağının girdi değeri *X*, çıktı değeri *h*'dir. Hücreden çıkan bir değer yine kendisine gelerek, bir döngü

oluşturmaktadır. Bu döngü ile önceki zamanın bilgileri de kullanılabildiğinden yeni bilgi, eski bilgi kullanılarak anlamlandırılabilmekte ve böylelikle sınıflandırma yapılabilmektedir.



Şekil 2.9: Tekrarlayan Sinir Ağları İçerisindeki Döngü [49].

Geleneksel yapay sinir ağlarında, hücrelerden çıkan sonuçlar tekrardan kendilerine girdi olarak gelmemektedir. RNN'de ise hücreden çıkan sonuç, tekrardan kendisine girdi olarak gelmektedir. RNN açılırsa aşağıdaki şekildeki gibi bir mimari ortaya çıkmaktadır. Zaman diliminde, aynı hücre kendini birden fazla tekrar etmektedir. Böylelikle de kareler arasında anlamlandırma kurulabilmektedir.



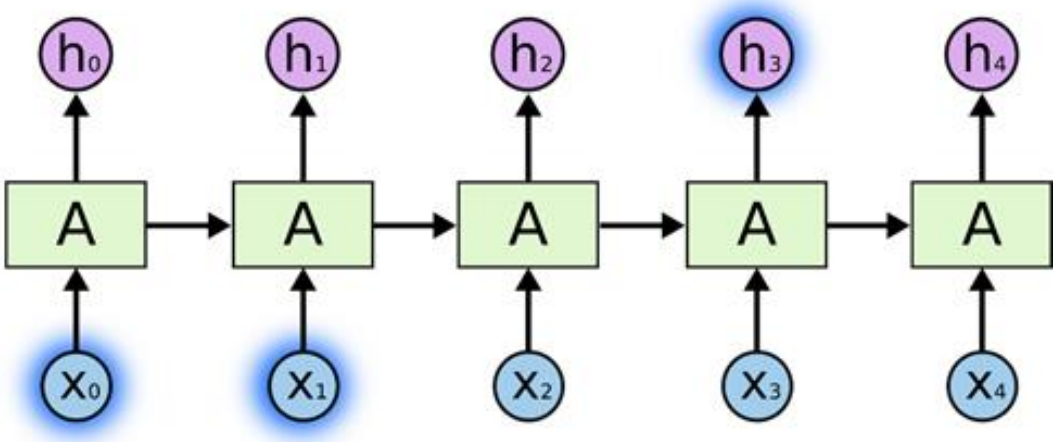
Şekil 2.10: Açık Hale Getirilmiş Bir Tekrarlayan Sinir Ağları [49].

RNN'ler, geçmiş ile bağlantı kurup anlamlandırma özniteliğinden dolayı, zaman bazlı problemlerde başarılı sonuçlar vermektedir. Ancak RNN'lerde, hangi aktiviteler hatırlanacak, ne kadar süre hatırlanacak bilinmemektedir. Bütün bilgiler, modelin içerisinde tutulmaktadır. Aktiviteler için bazı bilgiler önemliyken, bazı bilgiler gereksizdir. Bu yüzden bazı aktivitelerin sınıflandırılmasında, tüm geçmişin saklanmasına gerek yoktur [49], [50].

RNN'in bir döngü yaratabilmesi ve sıralı biçimde gerçekleşen olayları birbirleriyle anlamlandırılabilmesi, son yıllarda RNN kullanımının yaygınlaşmasının başlıca nedenidir. RNN algoritması; çeviri yapmada, resimler için altyazı oluşturmada, kredi kartı sahtekârlığını tespit etmede, gürültülü verilerden gürültüsüz verilerin elde edilmesinde, büyük metinlerin özetlerinin çıkarılmasında, el yazısı tanımada, konuşma tanımada ve otomatik wikipedia makalelerinin yazılmasında kullanılabilmektedir [28].

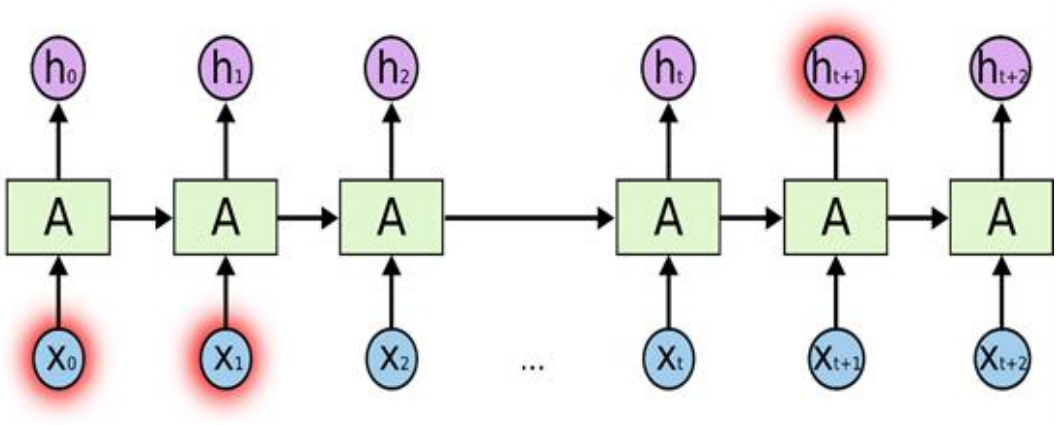
2.10.3. Uzun Kısa Süreli Bellek Ağları

Uzun Kısa Süreli Bellek (Long Short-Term Memory, LSTM) Ağları Schmidhuber ve Hochreiter tarafından 1997 yılında tanıtılmıştır [51].



Şekil 2.11: Kısa Süreli Bağımlılıklar [49].

Aktivite sınıflandırılmasında, gerekli bilgi çok önceden oluşmuş ise, bu bilgiye ulaşılamayabilir. Bazı durumlarda ise, bir önceki karedeki olay ile şimdiki karedeki olay birbiri ile bağlantılıdır. Örneğin, aktivite sınıflandırılması yapılacak olan videoda, sırasıyla bazı kişiler yemek masasına oturuyor olsun; böyle bir videoda, önceden masaya oturmuş kişilerden, bir sonraki gelen kişinin de masaya oturacağını tahmin etmek RNN için zor değildir. Çünkü bir sonraki karenin tahmin edilebilmesi için gerekli olan masaya oturma aktivitesi, çok yakın zamanda gerçekleşmiştir.



Şekil 2.12: Uzun Süreli Bağımlılıklar [49].

Bazı aktiviteler, yemek masasına oturma aktivitesinden çok daha karmaşıktır. Örneğin, sınıflandırma yapılacak video, yemek masasında oturulup yemeğe başlandıktan sonra gelen

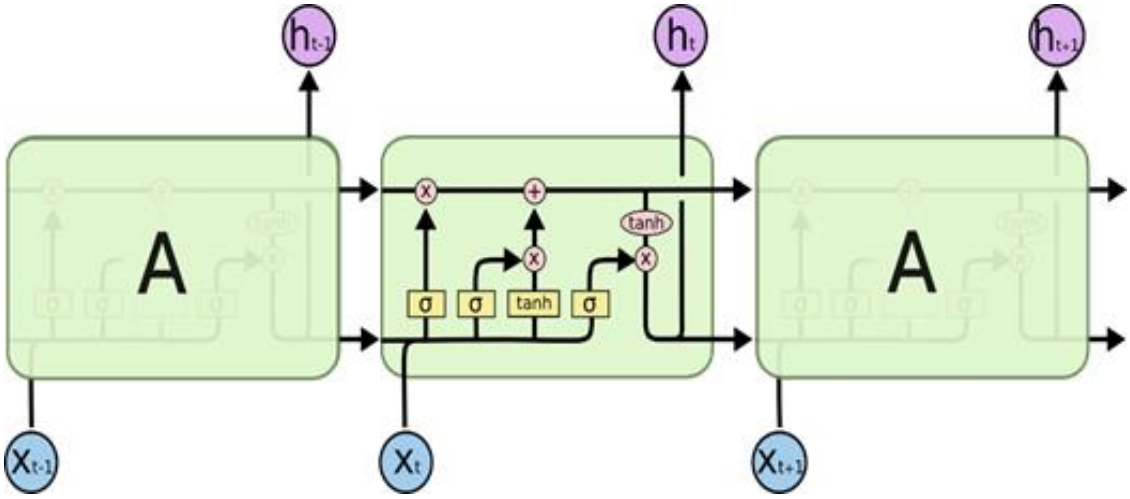
bir kişinin aktivitesi olsun. Yemeğe geç gelen kişinin, yemeğe oturacağının tahminin yapılması insanlar için zor değildir. Fakat RNN için yemeğe oturma aktivitesi bitip, aralara başka aktiviteler girdiği için, yeni kişinin yemeğe oturacağını tahmin etmek zor olmaktadır. Diğer bir deyiş ile RNN yapılarında dizi içerisindeki kısa süreli bağımlılıklar Şekil 2.11'de gösterildiği gibi başarılı bir şekilde yönetilebilirken, Şekil 2.12'de gösterildiği gibi RNN yapılarında uzun süreli bağımlılıkların çözümlenmesinde başarım yüksek değildir.

RNN'lerin çok önceden olan olayları tahmin edebilmesi için farklı bir mimari yapıya ihtiyaçları vardır. Bu tür problemlerde, daha iyi çalışan RNN'lerin, bir çeşidi olan Uzun Kısa-Süreli Bellek Ağları kullanılmaktadır.

Teoride, RNN'lerin uzun geçmişteki aktiviteleri, iç mimarisinde kendini tekrarlamakta olduğu için, hatırlayabilme kapasitesine sahiptir. Ancak hatırlanabilmesi için parametrelerin titizlikle seçilmesi gerekmektedir. Böyle bir parametre seçimi, pratikte mümkün olmadığından, RNN'ler uzun geçmişi öğrenemezler (hatırlayamazlar) [49], [50].

LSTM olarak bilinen uzun kısa süreli bellek tekrarlayan sinir ağları, bir cümlede kelimeler arasındaki uzak bağımlılıkları öğrenebilen özel bir RNN türüdür. Temel RNN'ler, uzak kelimeler arasındaki bu tür korelasyonları öğrenemezler. Uzun kısa süreli hafıza tekrarlayan sinir ağlarının mimarisi, geleneksel RNN'lerden biraz farklıdır [17].

Uzun Kısa Süreli Bellek ağları, RNN'lerin uzun süreli hatırlama sorunlarını çözmek amacıyla ortaya çıkmıştır. Geleneksel RNN'lerin tekrarlayan kısmında tek bir tanjant fonksiyonu (katmanı) bulunmaktadır. LSTM'lerde tek bir sinir katmanı yerine tekrarlayan zincir şeklinde dört farklı katman bulunmaktadır. LSTM ağı mimarisi Şekil 2.13'te gösterilmektedir [49].



Şekil 2.13: LSTM Ağı Mimarisi [49].

Yukarıdaki şekilde okların her bir çizgisi, bir düğümün çıktısından diğer düğümlerin girişlerine kadar bir vektörü taşır. Pembe daireler vektör eklenmesi gibi noktasal işlemleri temsil ederken; sarı kutular sinir ağı katmanlarını öğrenir. İki çizginin bağlanmasıyla birleşen iki farklı vektör başka bir düğüme girdi oluşturur. Çatal şeklindeki çizgiler bir düğümden çıkan vektörün kopyalandığını ve başka düğümlere gittiğini belirtir.

LSTM yapısını aşamalı olarak incelemek gerekirse, LSTM yapısı genel olarak Unutma Kapısı, Girdi Kapısı ve Çıktı Kapısı olarak 3 ayrı bölümden oluşur. LSTM yapısında h_t çıktısı x_t girdisi bir önceki durum olan h_{t-1} durum bilgisi ile sırayla hesaplanmaktadır:

$$f_t = \sigma(W_f.[h_{t-1}, x_t] + b_f) \quad (2.2)$$

$$i_t = \sigma(W_f.[h_{t-1}, x_t] + b_f) \quad (2.3)$$

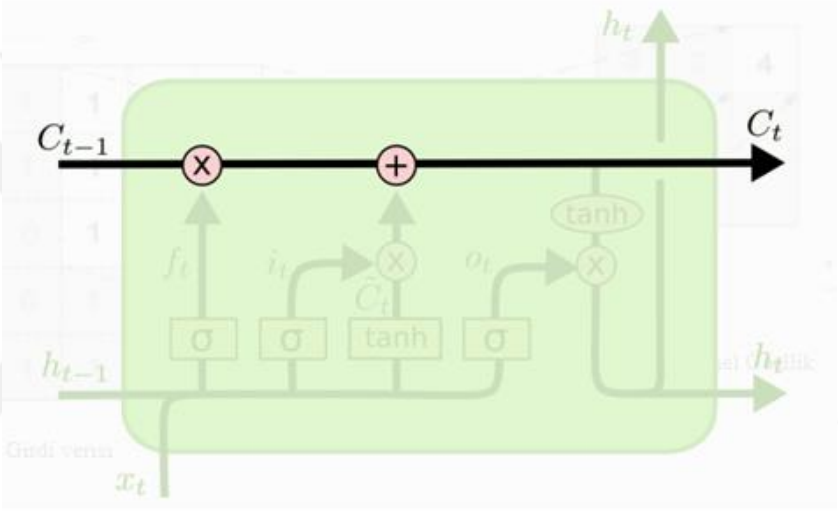
$$\tilde{C_t} = tanh(W_C.[h_{t-1}, x_t] + b_C) \quad (2.4)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C_t} \quad (2.5)$$

$$o_t = \sigma(W_o.[h_{t-1}, x_t] + b_o) \quad (2.6)$$

$$h_t = o_t * \tanh(C_t) \quad (2.7)$$

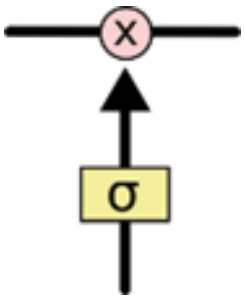
Burada i_t, f_t, o_t ve c_t sırasıyla *t* anındaki *i, f, o* ve *c* değerlerini temsil eder. *W*, gizli katmanın kendi kendini güncelleyen ağırlıklarını ve *b* terimi sapma vektörünü belirtir. *σ* ve *tanh* sırasıyla *sigmoid* ve *hiperbolik tanjant* fonksiyonudur. *(*)* operatörü noktasal çarpımı ifade etmektedir. Tüm kapı değerleri ve gizli katman çıktıları [0, 1] aralığındadır [52].



Şekil 2.14: LSTM Hücre Durumu [49].

LSTM'lerin kilit noktası hücre durumu şekil 2.14'te olduğu gibi, yatay çizgi diyagramın üstünden geçer. Hücre durumu bir tür taşıma bandı gibidir. Sadece tüm küçük doğrusal etkileşimlerle, tüm zincir boyunca doğrudan uzanır. Bilginin değişmeden akması çok kolaydır.

LSTM ağlarının, kapılar denilen yapılar tarafından dikkatlice düzenlenen hücre durumundan bilgi çıkarma veya hücre durumuna bilgi ekleme kabiliyeti vardır. LSTM kapıları, isteğe bağlı olarak bilgiyi iletmenin bir yolu olmaktadır. Sigmoid bir sinir ağı katmanından ve noktasal çarpım yönteminden oluşurlar. Şekil 2.15'te bu işlem gösterilmektedir.

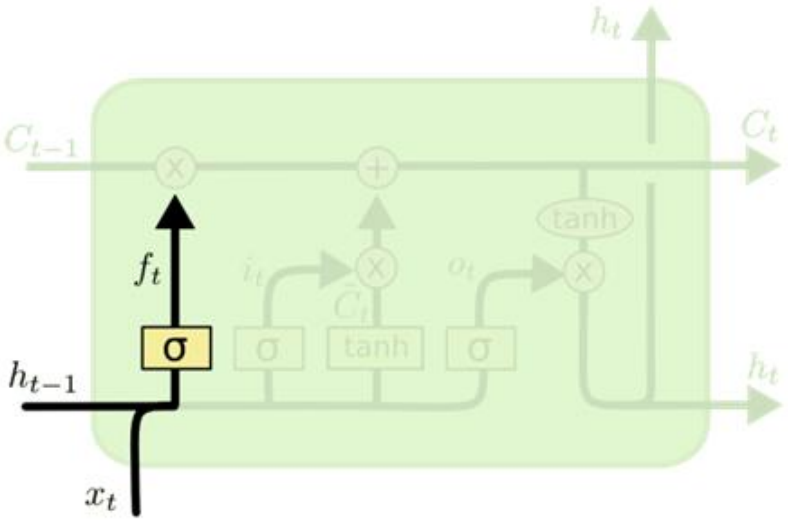


Şekil 2.15: Noktasal Çarpım ve Sigmoid Katmanı [49].

Sigmoid katmanı, her bir bileşenden ne kadarının geçmesi gerektiğini tanımlayan sıfır ile bir arasında rakamlar verir. Sıfır değeri "hiçbir şeyin geçmesine izin vermeyin" anlamına gelirken, birin değeri "her şeyin geçmesine izin verin" anlamına gelir. Bir LSTM, hücrenin durumunun korunması ve denetlenmesi için bu kapılardan üçüne sahiptir.

LSTM'deki ilk kapı unutma kapısıdır; amacı durum bilgisinin ne kadarının unutulacağı, ne kadarının bir sonraki aşamaya aktarılacağına karar vermektir. Bu karar *sigmoid* katmanı tarafından verilir. Hücre durumuna 0 ile 1 arasında bir sayı verir ve eğer 1 çıkarsa "bunu tamamen sakla", 0 çıkarsa "bunu tamamen at" anlamındadır. Unutma kapısına ait katmanın matematiksel modeli (2.2) eşitliğinde gösterilmektedir.

$$f_t = \sigma(W_f . [h_{t-1}, x_t] + b_f) \tag{2.2}$$

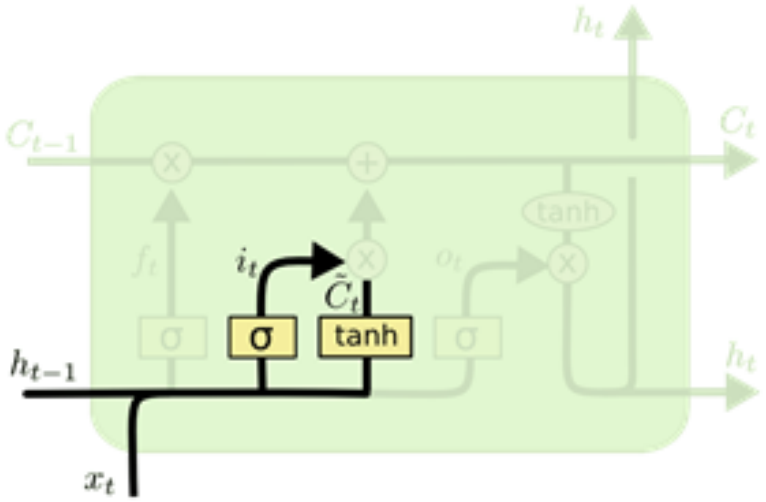


Şekil 2.16: LSTM Unutma Kapısı [49].

Hücre durumunda hangi yeni bilgilerin tutulacağının kararı bir sonraki adımda verilmektedir. Öncelikle, "girdi kapısı katmanı" adı verilen bir sigmoid katmanı tarafından, hangi değerlerin güncelleneceği kararı verilir. Sonrasında, bir tanh katmanıyla, yeni aday değerlerin vektörü oluşturulur. t anındaki x_t girdisi ve bir önceki h_{t-1} çıktısına göre bilgisine eklenecek olan bilgiyi hesaplayan sigmoid katmanı (2.3) eşitliğinde ve durum bilgisine eklenecek olan $\tilde{C}_t$ değerinin hesap formülü (2.4) eşitliğinde gösterilmektedir.

$$i_t = \sigma(W_f . [h_{t-1}, x_t] + b_f) \tag{2.3}$$

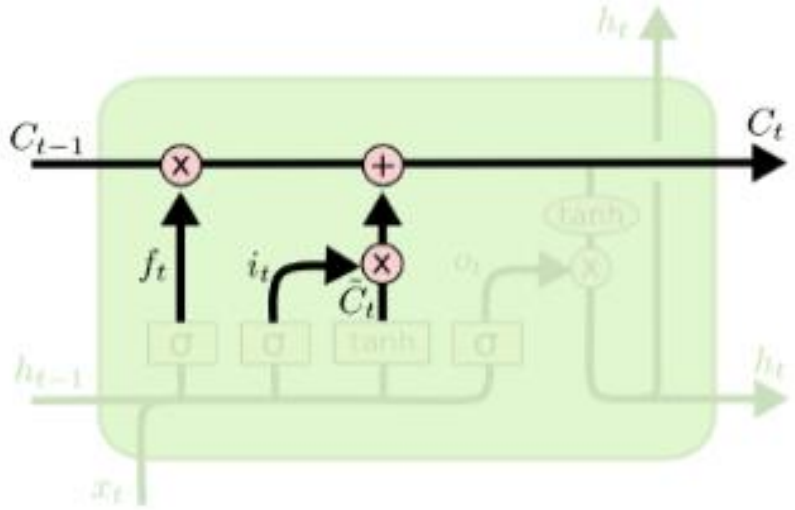
$$\tilde{C}_t = tanh(W_C . [h_{t-1}, x_t] + b_C) \tag{2.4}$$



Şekil 2.17: LSTM Girdi Kapısı Katmanı ve Tanh Katmanı [49].

Yeni saklanan değerin ne olacağına, girdi katmanındaki tanjant katmanı ile karar verilmektedir. Eşitlik (2.5)'te gösterildiği gibi girdi kapısından gelen vektör, sigmoid katmanından gelen değer olan i_t değeri ile tanjant katmanından gelen değer olan $\tilde{C}_t$ 'nin çarpılması ile belirlenmektedir. Girdi kapısından çıkan vektör, bir önceki aşamada belirlenmiş olan $(f_t * C_{t-1})$ değeri ile toplanmaktadır. Şekil 2.18'de bellekte bekleyen veri ile bellekte saklanacak yeni verinin, yer değiştirilmesi işlemi gösterilmektedir.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \tag{2.5}$$

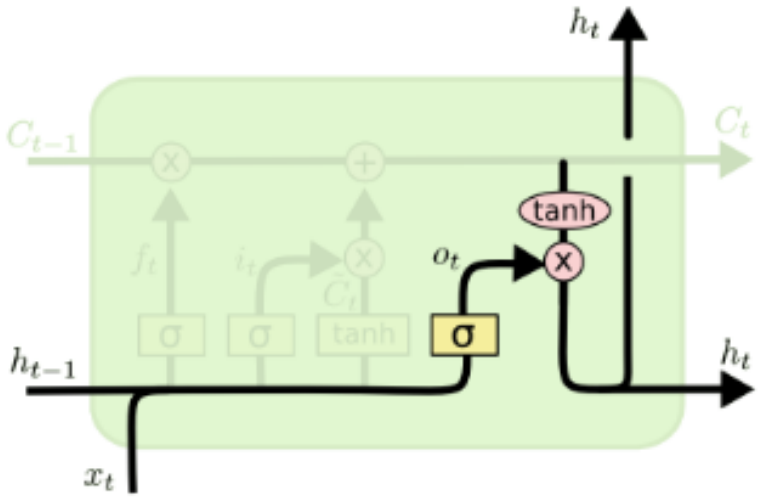


Şekil 2.18: LSTM Durum Bilgisinin Değişimi ve Aktarımı [49].

Son aşama olarak çıktı kapısında sistemin *t* anındaki h_t çıktısı hesaplanır. Çıktı katmanı, tanjant ve sigmoid katmanı olmak üzere iki katmandan oluşmaktadır. Tanjant katmanı ile saklanan bilginin ne kadarının kullanılacağı hesaplanmakta ve (-1) ile 1 arasında değer çıkmaktadır. *Sigmoid* katmanının çıktısı ise 0 ile 1 arasında ve bu katman yeni gelen bilginin kullanılıp kullanılmayacağına karar vermektedir. *Sigmoid* ve *tanjant* katmanlarından gelen değerler çarpılarak oluşan değer çıktı değeri olarak belirlenmektedir. Bu işlemler aşağıdaki eşitliklerde gösterilmektedir [49].

$$o_t = \sigma(W_o.[h_{t-1}, x_t] + b_o) \tag{2.6}$$

$$h_t = o_t * \tanh(C_t) \tag{2.7}$$



Şekil 2.19: LSTM Çıktı Kapısı [49].

LSTM ağları kullanılarak resimlerden otomatik başlık oluşturma, sessiz videolara otomatik ses ekleme, ilişkili metinlerden kelime üretme, düzensiz dillerde öğrenme, çevrimdışı el yazısının tespit edilmesi gibi birçok uygulama yapılmıştır [28].

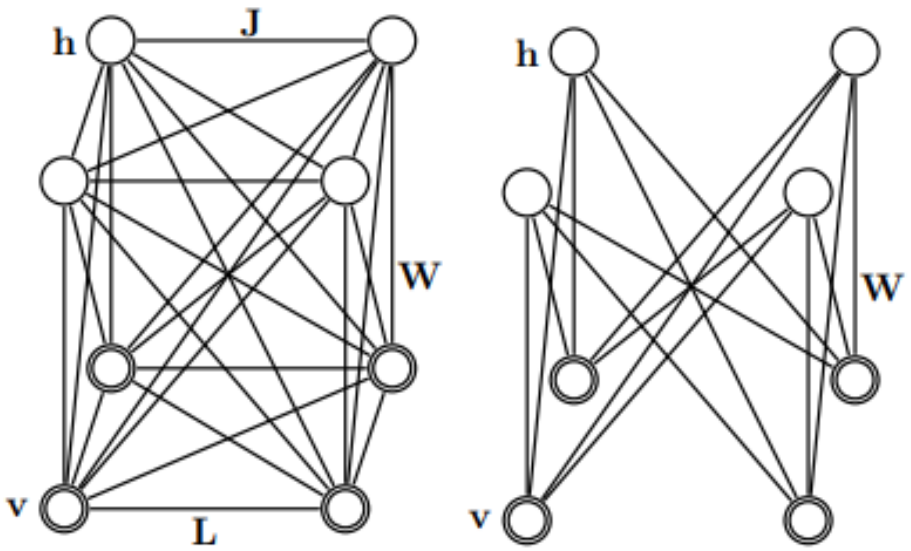
LSTM'ler daha iyi güncelleme denklemleri ve daha iyi geriyayılımla bilinir. Cümle oluşturma, cümle sınıflandırma, zaman serilerinin sınıflandırılması, konuşma tanıma, elyazısı tanıma, çok sesli müzik modellemesi gibi birçok alanda kullanılırlar. LSTM mimarileri görüntü altyazılama (image captioning), dil çevirisi ve elyazısı tanıma görevlerinde son yıllarda sektöründe öncü değerlendirmeler göstermektedir [38].

2.10.4. Kısıtlı Boltzman Makineleri

Harmonium adı altında ortaya atılan Kısıtlı Boltzmann Makineleri (Restricted Boltzmann Machine, RBM), derin olasılık modellerinin en yaygın yapı taşlarındandır. RBM'ler, bir görünür değişkenler katmanı ve bir tekli gizli değişkenler katmanı içeren yönlendirilmemiş olasılıklı grafiksel modellerdir. RBM'ler daha derin modeller oluşturmak için birbiri üzerine istiflenebilir [32].

Gizli bir katmanı ve görünür bir katmanı olan iki katmanlı Genel Boltzmann makine mimarisi ile kısıtlı Boltzmann makine mimarisi Şekil 2.20'de gösterilmektedir [53]. Kısıtlı Boltzmann makinesinde tüm gizli ve görünür katmanların birimleri arasında çift yönlü bağlantı varken,

gizli ve görünür birimlerin kendi aralarında bağlantıları yoktur. Genel Boltzmann makinesinde her iki bağlantı tipi bulunmaktadır. RBM'de kısıtlı terimi, ağdaki bu sınırlamayı ifade eder [17].



Şekil 2.20: Genel Boltzmann Makinesi ve Kısıtlı Boltzmann Makinesi [53].

Boltzmann makineleri, görünür bir katman ve tek bir gizli katman içeren, yönlendirilmemiş olasılıklı grafik modeller olarak tanımlanabilir. RBM'ler, bir boyuttaki verileri farklı bir boyutta temsil etmenin bir yolu olarak düşünülebilir. Gizli katmanın boyutu görünür katmanın boyutundan küçük olduğunda, RBM'ler verinin boyutsal bir şekilde azaltılmasını sağlar. RBM'ler genellikle ikili veriler üzerinde eğitilir [17].

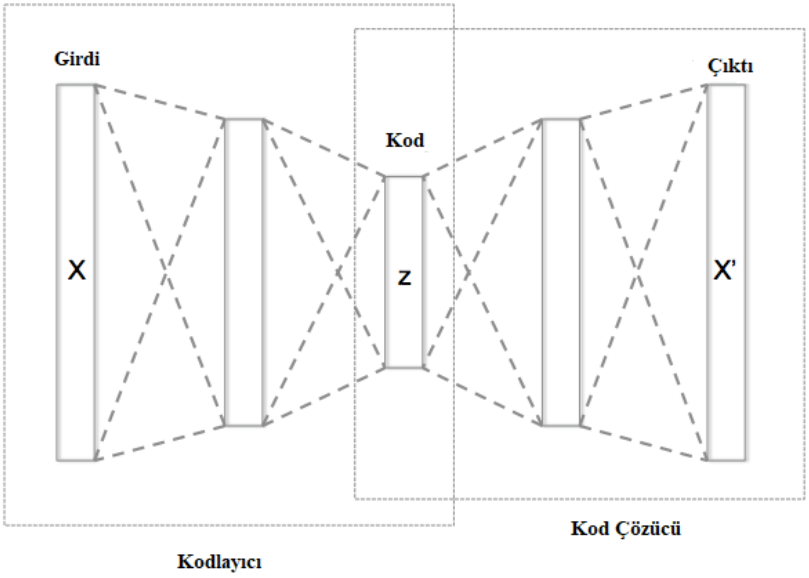
RBM'ler, kümeleme, özellik öğrenimi, boyut indirgeme, işbirlikçi filtreleme ve konu modelleme gibi çeşitli uygulamalarda kullanılan bir algoritmadır [28].

2.10.5. Derin Oto-Kodlayıcılar

Oto-kodlayıcılar, giriş faaliyetlerini çıkış katmanında yeniden yapılandırmaya çalışan bir veya daha fazla gizli katmanı olan ileri beslemeli bir sinir ağıdır [54].

Otomatik kodlayıcı ağı genellikle girdi ve çıktı katmanları ve gizli katman olarak üç katmandan oluşur. Girdi katmanı ve gizli katman kombinasyonu kodlayıcı olarak işlev görürken, gizli katman ve çıktı katmanı kombinasyonu kod çözücü olarak işlev görür [17].

Oto-kodlayıcı ile geleneksel sinir ağının temel farkı, çıktı katmanının boyutudur. Bir oto-kodlayıcıda, çıktı katmanının boyutu her zaman girdi katmanının boyutuyla aynıdır. Bunun yanı sıra, bir otomatik kodlayıcı ağındaki en derin gizli katmanın boyutu her zaman girdi ve çıktı katmanlarının boyutlarından daha küçüktür [55]. Şekil 2.21'de gösterildiği gibi, oto-kodlayıcı ağı "kodlayıcı" ve "kod çözücü" olmak üzere iki bileşen içerir [56].



Şekil 2.21: Bir Oto-Kodlayıcının Şematik Yapısı [56].

Kodlayıcı ağı, yüksek boyutlu giriş verilerini düşük boyutlu bir koda dönüştürür. Kod çözücü ağı, orijinal yüksek boyutlu verileri düşük boyutlu koddan yeniden yapılandırır [55].

Derin oto-kodlayıcı (Deep auto-encoders) birçok oto-kodlayıcının ardışık olarak katmanlı şekilde bağlanmasıyla elde edilmektedir [57]. Deneysel olarak, derin otomatik kodlayıcılar karşılık gelen sığ veya doğrusal otomatik kodlayıcılardan çok daha iyi sıkıştırma sağlar [32].

Bir oto-kodlayıcı modelindeki gizli katmandan oluşturulan değerler, ardından gelen oto-kodlayıcı modelindeki giriş katmanı olacak biçimde art arda bağlanmakta ve aynı şekilde eğitilmektedir. Bazen başarı oranının düşmesine yol açan sebep oto-kodlayıcı modellerinin birbirinden bağımsız şekilde eğitilmeleridir. Hassas ayar yöntemiyle bu problemler giderilebilmektedir. Bu yöntemde elde edilen her bir model birleştirilip veri etiketlerine de

dikkat edilerek ağırlıklar toplu şekilde tekrar güncellenmektedir. Oto-kodlayıcı modelindeki çıkış katmanı için, giriş katmanındaki verilerin aynısından elde etmeye çalışmak, o verinin aşırı öğrenilerek ezberlenmesine ve test verisi için düşük başarı oranları ile sonuçlanmasına sebep olabilmektedir. Giriş katmanında kullandığı veriye çeşitli gürültüler ekleyerek, çıkış katmanında gürültüsüz giriş değerleri elde etmeye çalışan gürültü giderici oto-kodlayıcı modeli ile bu soruna çözüm oluşturulmuştur. Bu model sayesinde sistem, eğitim verisinde yer almayan farklı örüntüdeki verileri de öğrenmektedir [57].

2.11. METİN MADENCİLİĞİ

Veri madenciliği (data mining), büyük miktardaki verilerden ilginç desenleri ve bilgileri keşfetme sürecidir [1]. Metin madenciliği (text mining) ise, yapılandırılmamış metinden ilginç, anlaşılması zor olan bilginin keşfi ve çıkarılmasıdır [58].

Metin madenciliği uygulamaları veri kaynağı olarak metinleri ele alan veri madenciliği çalışmalarıdır, yani metin madenciliği metin halindeki verilerden yapısal hale getirilmiş veri oluşturmayı amaçlamaktadır. Örnek vermek gerekirse; metinlerin sınıflandırılması, bölütlenmesi, metinlerden konu çıkarımı, sınıf tanecikleri üretimi, duygusal analiz, metin özetleme, varlık ilişki modellemeleri gibi çalışmaları hedefler. Bu amaçlara ulaşabilmek amacıyla metin madenciliği uygulamaları kapsamında bilgi getirimi, hece analizi, kelime frekans dağılımı, desen tanıma, etiketleme, bilgi çıkarımı, veri madenciliği ve görselleştirme vb. yöntemler kullanılmaktadır [59].

Metin madenciliği, genel olarak, bir kullanıcının bir dizi analiz aracı kullanarak bir belge koleksiyonuyla etkileşime girdiği, bilgi yoğun bir süreç olarak tanımlanabilir. Veri madenciliğine benzer şekilde, metin madenciliği, ilginç modellerin tanımlanması ve araştırılması yoluyla veri kaynaklarından faydalı bilgiler çıkarmayı amaçlamaktadır. Bununla birlikte, metin madenciliği söz konusu olduğunda, veri kaynakları belge koleksiyonlarıdır ve ilginç modeller resmi veri tabanı kayıtları arasında değil, bu koleksiyonlardaki belgelerde bulunan yapılandırılmamış metin verilerinde bulunmaktadır.

Metin madenciliği kuşkusuz, ilham ve yönünün büyük kısmını veri madenciliği konusundaki özgün araştırmalardan almaktadır. Bu yüzden, metin madenciliği ve veri madenciliği

sistemlerinin birçok mimari benzerliği bulunmaktadır. Bununla birlikte odak noktası bakımından farklılık gösterebilmektedir.

Veri madenciliği, verilerin zaten yapılandırılmış bir biçimde yüklenmiş olduğunu varsaydığından, ön işleme odağının çoğu iki kritik görevi yerine getirir: Verileri temizleme ve normalleştirme ve çok sayıda tablo birleşimi oluşturma. Metin madenciliği sistemlerinde aksine ön işleme işlemleri, doğal dil metinleri için temsili özelliklerin tanımlanması ve çıkarılmasına odaklanmaktadır. Bu ön işleme işlemleri, metin koleksiyonlarında depolanan yapılandırılmamış verilerin daha açık bir şekilde yapılandırılmış bir ara formata dönüştürülmesinden sorumludur.

Metin madenciliği; veri madenciliği, makine öğrenmesi, doğal dil işleme, bilgi edinme ve bilgi yönetiminden gelen teknikleri birleştirerek aşırı bilgi yüklemesi (information overload) problemini çözmeye çalışan bir bilgisayar bilimi alanıdır [2].

Bilgilerin önemli bir kısmı, haberler, teknik makaleler, kitaplar, dijital kütüphaneler, e-posta mesajları, bloglar ve web sayfaları gibi metin olarak saklanır. Bu nedenle, metin madenciliği araştırmaları çok aktif hale gelmiştir. Önemli bir amacı, metinden yüksek kalitede bilgi elde etmektir. Bu, tipik olarak, istatistiksel desen öğrenme, konu modelleme ve istatistiksel dil modelleme gibi araçlarla örüntülerin ve trendlerin keşfi yoluyla yapılır.

Metin madenciliği genellikle girdi metninin yapılandırılmasını gerektirir (örneğin, bazı türetilmiş dilsel özelliklerin eklenmesi ve diğerlerinin çıkarılması ile birlikte ayrıştırılması ve ardından bir veri tabanına eklenmesi). Bunu, yapılandırılmış veri içinde desenlerin türetilmesi ve çıktının değerlendirilmesi ve yorumlanması izler. Metin madenciliğindeki “yüksek kalite” genellikle uygunluk, yenilik ve ilginçliğin birleşimini ifade eder [1].

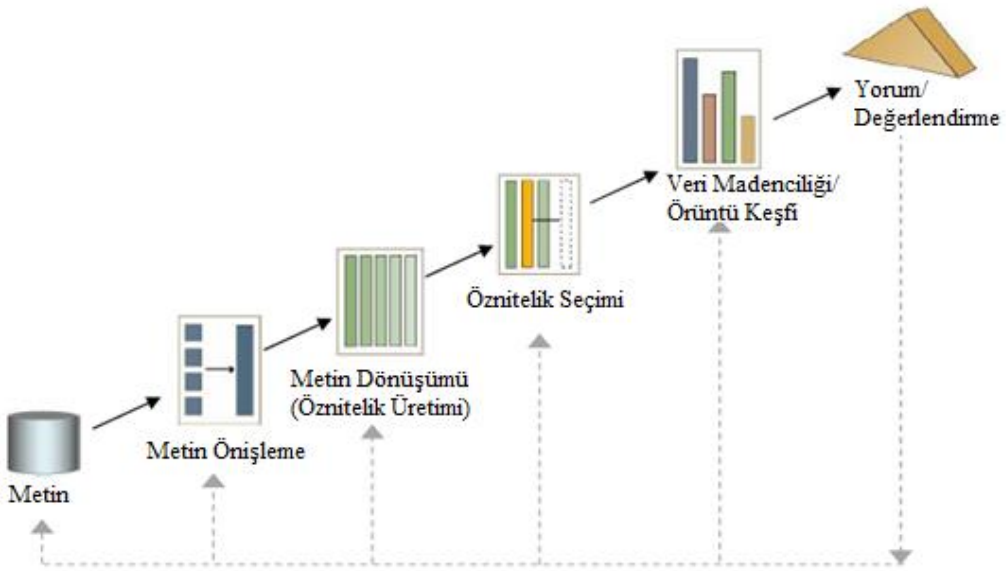
2.11.1. Metin Madenciliği Adımları

Metin madenciliği, metinlerin içerisindeki kalıpları tanımlar ve bilinmeyen bilgiyi meydana çıkararak, mevcut yapısı ile metinlerden oluşan belgeleri bilgiye çeviren önemli bir süreçtir. Bu süreçte metin öncelikle bir önişlemeden geçer, anlamlı olmayan sözcükler çıkarılır, metinler sınıflandırılır ve sonucunda klasik veri madenciliği teknikleri kullanılarak geniş hacimli metinlerin analizi yapılır ve ortaya çıkan performans sonuçları değerlendirilerek yorumlanır [60].

Metin madenciliği işlemleri, veri madenciliğine benzer olarak aşağıdaki adımlardan oluşmaktadır.

- Metin Önişleme
- Metin Dönüşümü (Öznitelik Üretimi)
- Öznitelik Seçimi
- Veri Madenciliği/Örüntü Keşfi
- Yorum/Değerlendirme

Metin madenciliğinin adımları, Şekil 2.22'de gösterilmektedir [61].



Şekil 2.22: Metin Madenciliği Adımları [61].

2.11.1.1. Metin Önişleme

İlgilenilen konularda bilgiye erişim sistemleri kullanılarak metin (veya belge) toplama süreçleri için günümüzde genellikle internet yoluyla yapılmaktadır, bilhassa Google gibi arama motoru kullanılmaktadır. Metin madenciliğinde kullanılan sistemler; çevrim içi veri tabanları, veri tabanları veya kişisel bilgisayarlarda yer alan metin halindeki verilerle

oluşturulmuş olan koleksiyonlardır [61]. İşlenecek metinlerin koleksiyonu oluşturulduktan sonra metin önişleme aşaması ile devam edilmektedir.

Etkili metin madenciliği işlemleri, ileri veri ön işleme yöntemlerine dayanmaktadır. Metin madenciliğinde ham yapılandırılmamış verileri hazırlamak için çok farklı ön işleme teknikleri gerekmektedir. Görev odaklı ön işleme yaklaşımları, görevler ve alt görevler açısından yapılandırılmış bir belge gösterimi oluşturma sürecini öngörür ve genellikle bir PDF belgesinden başlıklar ve yazarlar çıkarmak gibi çözülmesi gereken bir tür hazırlık amacı veya problemi içerir. Diğer ön işleme yaklaşımları, doğal dil metinlerine de uygulanabilecek karmaşık olayları analiz etmek için resmi yöntemlerden türetilen tekniklere dayanır. Bu tür yaklaşımlar sınıflandırma şemalarını, olasılıksal modelleri ve kural tabanlı sistem yaklaşımlarını içerir [1].

Metin önişleme süreci; metinde bulunan istenmeyen noktalama işaretlerinin kaldırılması, kelimelerin tamamının küçük veya büyük harfe dönüştürülmesi, metnin kelimelere ayrılması, kelimelerin köklere ayrılması, gereksiz olan kelimelerin (stopwords) çıkarılması, kelimelerin yazım kurallarına uygunluğunun tespit edilmesi ve mevcut olan hataların düzeltilmesi işlemlerini içermektedir. Metin madenciliğinde en büyük problem işlenecek veri setinin yapısal hale getirilmemiş olmasıdır. Çoğunlukla doğal dil ile yazılan belgeler üzerinde işlemler yapan metin madenciliği çalışmasındaki önişleme adımında, verinin temizlenmesinin yanı sıra verinin uygun format haline getirilme işlemi de gerçekleştirilmektedir [61].

Önişleme, herhangi bir makine öğrenmesi veya derin öğrenme görevinden önce metin içerikli dokümanların hazırlanmasında en kritik adımıdır. Dizgelere (Tokenlere) ayırma, gereksiz sık kullanılan kelimelerin (stopwords) atılması ve kelime köklerini bulma en yaygın kullanılan ön işleme yöntemlerindendir.

Dizgelere ayırma (tokenization): Tüm ortak ayırıcılar, işleçler, noktalama işaretleri ve yazdırılamayan karakterler kaldırılır. Daha sonra tüm metin küçük veya büyük harfe dönüştürülür ve metinlerdeki kelimeler ayrılarak kelime grupları elde edilir [62].

Durma kelimeleri filtreleme (stopwords filtering): Literatürde *stopwords* olarak geçen durma kelimeleri her dokümanda sıkça bulunan, tek başına herhangi bir anlam içermeyen ve dokümanlar için herhangi bir ayırt edici özelliği olmayan kelime listeleridir. Bu gereksiz

kelimelerini temizlemek hem analiz süresini kısaltırken hem de daha doğru ve güvenilir sonuçlar alınmasına neden olmaktadır [63].

Kök bulma (stemming): Kelimeleri en basit hallerine dönüştürme işlemidir. Kök bulma işlemleri, isimlerdeki çoğul ekini atma, fiillerdeki fiil çekim eklerini atarak fiil kökünü ayırma vb. işlemlerdir. Porter tarafından geliştirilen kural tabanlı kök bulma algoritması İngilizce dilinde en çok kullanılmış olan yöntemdir ve halen yaygın şekilde kullanılmaktadır. Türkçe dilindeki metinler için ise birçok yöntem geliştirilmiştir [64].

2.11.1.2. Metin Dönüşümü (Öznitellik Üretimi)

Metin sınıflandırma çalışmalarında kullanılan öznitelikler modeller kullanılarak elde edilmektedir. Metin sınıflandırma çalışmalarında yaygın olarak kullanılan ve öznitelik olarak kelimelerin kullanıldığı model Kelime/Sözcük Çantası (BoW: Bag of Words) modeli olarak adlandırılır. Kelime çantası modelinde kelimelerin metin içeriğindeki sırası ve dizilişi önemli değildir.

Kelime çantası modeli kelimelerin dilbilimsel özellikleri ile değil metin içeriğinde gözlenme frekansları ile ilgilenmektedir. Ancak bu modelde öznitelik olarak kelimeler kullanıldığı için dil bağımlıdır ve metnin dile bağımlı önişlemlerden geçirilmesi gerekir. Öznitelik olarak metin içerisinden çıkarılan karakterlerin kullanıldığı model ise karakter seviye n-gram model olarak adlandırılır. Bu model gramer hatalarına, kısaltma ve noktalama işareti kullanımlarına karşı güçlüdür. Ayrıca karakter tabanlı n-gram model önişlem gerektirmez ve dilden bağımsız olarak çalışır.

Yapısal öznitelikler elde edilirken metnin yapısına bağlı olarak değişebilen özellikler öznitelik olarak değerlendirilir. İstatistiksel öznitelikler ise problemin türü ve çalışmanın amacına göre çeşitli dilbilimsel işlemler kullanılarak da elde edilebilir. Metin sınıflandırma çalışmalarında öznitelikler hangi model ile elde edilmiş olursa olsun terim olarak da ifade edilir. Öznitelikler elde edildikten sonra önişlemin son aşamasında terim ağırlıklandırma (TW: Term Weighting) işlemi uygulanır. Terim ağırlıklandırma ile her bir terim; ilgili terimin önemini hesaplayan ve görüldüğü belgenin sınıflandırılmasına yaptığı katkıyı gösteren bir ağırlık değeri ile ilişkilendirilir [65].

2.11.1.3. Öznitelik Seçimi

Öznitelik seçimi aşamasında; önişlemeden geçen metinlerdeki önemli kelimeler belirlenir (isimler, bileşik kelimeler, kısaltmalar, sayılar, tarihler, para birimleri vb.) ve ilişkili olmayan öznitelikler (özellikler) çıkarılır, sadece birkaç belgede gözlenen özellikler çıkarılır, birçok belgede gözlenen özellikler azaltılır [61].

Kelime gömme işlemi, aynı anlama sahip farklı kelimelerin benzer bir vektör ile temsil edilmesidir. Kelime gömme aslında, bireysel sözcüklerin önceden tanımlanmış bir vektör uzayında gerçek değerli vektörler olarak temsil edildiği sınıftır. Her kelime bir vektörle eşleştirilir ve vektör değerleri sinir ağına benzer bir şekilde öğrenilir. Bu nedenle teknik derin öğrenme alanına girmektedir. Vektör uzay boyutunda temsil edilen kelimeler arasındaki semantik özelliklerin bulunmasıdır.

Kelime gömme işlemlerinde *TF Kodlaması, TF-IDF* (Terim Frekansı-Ters Metin Frekansı), *İkili Kodlama* (Binary), *Word2Vec Kodlaması* gibi birçok yöntem kullanılmaktadır. Makine öğrenme algoritmaları metinlerin vektör değerlerini kullanır. Vektör değerlerinin kullanılması kelime gömme yönteminin farklı alanlarda kullanılmasına olanak sağlamaktadır [65].

2.11.1.4. Veri Madenciliği

Bu aşamada veri madenciliğinde olduğu gibi yapısallaştırılmış verilerin analiz edilmesi için makine öğrenme veya derin öğrenme algoritmaları kullanılmaktadır.

2.11.1.5. Yorum ve Değerlendirme

Veri madenciliği algoritmalarıyla verilerin analizinde ortaya çıkan sonuçların performans değerlendirme ölçütleri açısından değerlendirilip anlaşılır bir şekilde raporlanması aşamasıdır.

2.11.2. Metin Madenciliği Teknikleri

Bilgisayarlara metinlerin nasıl analiz edileceğini, anlaşıldığını ve üretildiğini öğretmek için doğal dil işleme ile teknolojiler üretilir. Metin madenciliği sürecinde bilgi çıkarımı, özetleme, kategorizasyon, kümeleme ve bilgi görselleştirme gibi teknolojiler kullanılmaktadır [66].

2.11.2.1. Bilgi Çıkarımı (Information Extraction)

Bilgi çıkarımı, yapılandırılmış bilgilerin otomatik çıkarılması anlamına gelmektedir [67]. Bilgi çıkarma işlemi, bilgisayarın temel ifadeleri ve metin içindeki ilişkileri tanımlayarak yapılandırılmamış metni analiz etmesi için ilk adımdır. Bu görevi yapmak için desen

eşleştirme işlemi, metinde önceden tanımlanmış dizileri aramak için kullanılır. Bilgi çıkarma görevi; dizgelere ayırmayı, adlandırılmış varlıkların tanımlanmasını, cümle segmentasyonunu ve konuşmanın bir kısmını atamayı içerir. İlk olarak ifadeler ve cümleler ayrıştırılır ve anlamsal olarak yorumlanır, daha sonra veri tabanına gerekli bilgi parçaları girilir [66].

2.11.2.2. Kategorizasyon (Categorization)

Metin kategorizasyonu, kategorilerin (sınıfların) önceden bilindiği ve her eğitim belgesi için kesin olduğu bir tür denetimli öğrenmedir. Kategorizasyon veya sınıflandırma, normal dil belgelerinin, içeriğine göre önceden tanımlanmış konu kümelerine atanmasıdır. Metin belgelerinin bir koleksiyonudur, her konunun doğru konusunu veya konularını bulma sürecidir [68].

Kategorizasyon kavramı, en basit tanımıyla bir veri seti üzerinde tanımlanmış olan belirli sayıdaki kategoriler arasında veriyi dağıtmaktır. Kategorize etme yöntemi olarak da literatürde adı geçen sınıflandırma yöntemi, tanımlanan eğitim verisinden sınıfların dağılım biçimini öğrenir ve sonrasında sınıflarının belirsiz olduğu test verileri tanımlandığında doğru olarak sınıflandırmaya çalışır. Veri seti üzerinde verilen bu sınıfları ortaya koyan değerler etiket olarak adlandırılır ve hem eğitim hem de test sırasında verinin sınıfının belirlenmesi amacıyla kullanılırlar [69].

Tipik metin sınıflandırma işlemi ön işleme, indeksleme, boyutsal indirgeme ve sınıflandırmadan oluşur [66].

2.11.2.3. Kümeleme (Clustering)

Kümeleme, pek çok metin madenciliği ve bilgi getirimi sistemlerinin bir parçası olarak gerçekleştirilen önemli bir yöntemdir [70]. Kümeleme, metin belgelerini farklı kümeleme algoritmaları uygulayarak gruplar halinde sınıflandırmak için denetimsiz bir işlemdir. Amacı, bilgide içsel yapılar bulmak ve bunları daha fazla çalışma ve analiz için önemli alt gruplara ayırmaktır. Nesnelerin kümeler adı verilen gruplar halinde sınıflandırıldığı denetimsiz bir süreçtir. Buradaki problem, verilen etiketsiz koleksiyonu önceden bilgi vermeksizin anlamlı kümelere ayırmaktır [68].

Kümeleme; veri madenciliği, belge getirimi, görüntü segmentasyonu ve örüntü sınıflandırma dahil çok çeşitli veri analizi alanlarında faydalıdır. Bu gibi birçok problemde, veriler hakkında

önceden çok az bilgi vardır ve karar vericinin veriler hakkında mümkün olduğunca az varsayım yapması gerekir. Bu durumlar için kümeleme yöntemi özellikle uygundur [1].

2.11.2.4. Görselleştirme (Visualization)

İnsan beyni görsel bilgileri metinden daha iyi işler, böylece çizelgeleri, grafikleri ve tasarım öğelerini kullanarak veri görselleştirmesi eğilimleri ve istatistikleri daha kolay bir şekilde açıklamanıza yardımcı olabilir. Metin biçimindeki verilerin kafa karıştırıcı olmasına rağmen, görsel bir biçimde gösterilen veriler insanların bu veriden çok daha hızlı ve kolay bir şekilde anlam çıkarmasına yardımcı olur [71].

Metin madenciliğinde görselleştirme yöntemleri, ilgili bilgilerin keşfedilmesini iyileştirebilir ve basitleştirebilir. Bireysel belgeleri veya belge gruplarını temsil etmek için, metin bayrakları belge kategorisini göstermek ve yoğunluk renklerini göstermek için kullanılır.

Görsel metin madenciliği, büyük metin kaynaklarını görsel bir hiyerarşiye koyar. Kullanıcı, yakınlaştırıp ölçeklendirerek belge ile etkileşime girebilir.

Bilgi görselleştirme üç adıma ayrılmıştır [66]:

(1) Veri hazırlama adımı; orijinal görselleştirme verilerinin kararlaştırılmasını, elde edilmesini ve orijinal veri alanını oluşturmayı içerir.

(2) Orijinal verilerden ihtiyaç duyulan görselleştirme verilerini analiz etme ve çıkarma ve görselleştirme veri alanını oluşturma süreci veri analizi ve çıkarma olarak bilinir.

(3) Görselleştirme haritalama adımı, görselleştirme veri alanını görselleştirme hedefine eşlemek için belirli haritalama algoritması kullanır.

2.11.2.5. Özetleme (Summarization)

Metin özetleme, kullanıcı için faydalı bilgiler sağlayan belirli bir metnin sıkıştırılmış bir versiyonunu otomatik olarak oluşturma işlemidir. Büyük kuruluşta veya şirkette, araştırmacı tüm belgeleri okumak için zamana sahip değildir, bu nedenle belgeyi özetler ve özeti ana noktalar ile vurgularlar [68].

Özetleme işlemi aşağıdaki adımları içerir [66]:

(1) Ön işleme, orijinal metnin yapılandırılmış bir gösterimini elde eder.

(2) Metni özet yapıya dönüştürmek için bir sonraki işlem adımında yapı algoritması uygulanır.

(3) Keşif aşamasında özet yapısından nihai özet elde edilir.

2.11.3. Metin Madenciliği Uygulama Alanları

2.11.3.1. Doğal Dil İşleme (Natural Language Processing)

Doğal dil işleme (NLP), yapılandırılmamış metin bilgisinin otomatik olarak işlenmesi ve analizi ile ilgilidir [72]. İnsanlar arasındaki iletişimdeki en büyük faktördür. Doğal dil işleme, dil faktörünü insan ve bilgisayar arasında en etkin şekilde kullanmayı amaçlamaktadır. Doğal dil işlemenin amacı, bilgisayarla doğal dil iletişimi sağlamaktır, bu nedenle bilgisayarın doğal dil kurallarını öğrenmesi gerekir. Bunun için bilgisayarın genel bir sözlüğe ve çeşitli algoritmalara ihtiyacı vardır [73].

Doğal Dil İşleme genel olarak konuşma ve metin gibi doğal dilin yazılım tarafından otomatik olarak değiştirilmesi olarak tanımlanır [74]. Metin madenciliği uygulamaları, metin halindeki veriler ile ilgilenen başka bir alan olan doğal dil işleme uygulamaları ile çoğunlukla birlikte kullanılmaktadır. Bu çalışmalar daha çok yapay zekâ teknolojisinin altında bulunan dil bilim bilgisine dayanan uygulamaları içermektedir. Metin madenciliği ile ilgili çalışmalar ise genellikle istatistiksel anlamda metin halindeki veriler üzerinden sonuçlar elde etmeyi amaçlar [59].

2.11.3.2. Bilgi Getirimi/Erişimi (Information Retrieval)

Kullanıcıların ihtiyaç duyduğu bilgiyi karşılayabilecek olan doküman koleksiyonlarındaki ilgili dokümanların her birine erişim sağlamak, ilgili olmayan dokümanları ise ayırmak bir bilgi erişim sisteminin ana görevidir. Bilgi erişimi, anahtar sözcükler kullanılarak büyük metin verilerinden arzu edilen özellikteki metinlere erişmeyi amaçlamaktadır. Günümüzde bilgi erişimine verilebilecek en iyi örnek sıklıkla kullanılan Google gibi arama motorlarıdır [75].

2.11.3.3. Bilgi Çıkarımı Sistemleri (Information Extraction Systems)

Bilgi çıkarımı sistemleri, yapılandırılmamış metni yapılandırılmış forma dönüştüren metin madenciliğine yönelik etkili yaklaşımlardan biridir. Bu sistemler doğal dilde yazılmış

belgelerle ilgilenir. Metinlerde kişi, yer ya da zaman adları gibi faydalı bilgiler çıkarmaya çalışır [73].

2.11.3.4. Soru Cevaplama Sistemleri (Question Answering Systems)

Soru cevaplama sistemi, verilen bir metni inceleyerek anlamlı olan soru ve cevapları çıkaran ya da verilen sorularla o soruların bir metin aracılığıyla cevaplarını bulmayı sağlayan etkili bir uygulama alanıdır. Bu problemin çözümü diğer bir yandan arama motorlarında da bir problem olan "konuşarak arama yapabilme" sorununun çözülmesini sağlamaktadır [76].

Soru cevaplama sistemleri, kullanıcıya doğru ve kesin cevapları döndürmek için mükemmel bir çözüm sunmaktadır. Soru Cevaplama sistemi, kullanıcıların doğal dil metninde soru sormalarını ve sonuç olarak kısa ve öz cevap almalarını sağlar [77].

Sistem ilk önce kullanıcı sorgusunu kaydeder ve analiz eder. Daha sonra, soruya göre, cevap türlerini (tarih, yer, isim vb.) belirler. Aynı zamanda, bir bilgi erişim sistemi kullanarak, soruların kelimelerini içeren belgelere erişir. Cevaplar bilgi erişim sistemleri tarafından belirlenen belgelerde aranır ve bu cevaplar puanlanır ve sıralanır. Yüksek puanlanan cevaplar kullanıcıya uygun bir ara yüz olarak sunulmaktadır.

Soru cevaplama sistemleri ile bilgi çıkarımı sistemleri arasındaki fark; bilgi çıkarımı sistemleri belge listesini kullanıcıya sunarken, soru cevaplama sistemleri, kelime öbeklerine veya kelimelere cevap olarak sunulmaktadır [73].

2.12. MODEL PERFORMANS DEĞERLENDİRME ÖLÇÜTLERİ

Metin sınıflandırma modellerinde yaygın olarak kullanılan değerlendirme ölçütleri karmaşıklık matrisi, doğruluk oranı, kesinlik, anma ve F-ölçütüdür. Bu ölçütlerden aşağıda kısaca bahsedilmiştir.

2.12.1. Karmaşıklık Matrisi (Confusion Matrix)

Karmaşıklık matrisi ile sınıflandırma modellerinin başarı oranları ile ilgili değerlendirmeler yapılmaktadır. Karışıklık matrisi ismiyle de adlandırılan karmaşıklık matrisi, bir sınıflandırma sistemi tarafından yapılan gerçek ve tahmin edilen sınıflandırmalar hakkında bilgi içerir. Bu tür sistemlerin performansı genellikle matristeki veriler kullanılarak değerlendirilir. Tablo 2.3'te, iki sınıflı bir sınıflandırıcı için karmaşıklık matrisi gösterilmektedir [78].

Karmaşıklık matrisindeki girdiler şu anlama gelir:

- Doğru Pozitif (True Positive, TP): Doğru sınıflandırılan pozitif veri sayısı,
- Doğru Negatif (True Negative, TN): Doğru sınıflandırılan negatif veri sayısı,
- Yanlış Pozitif (False Positive, FP): Yanlış sınıflandırılan pozitif veri sayısı,
- Yanlış Negatif (False Negative, FN): Yanlış sınıflandırılan negatif veri sayısı.

Bu dört sayı, ikili sınıflandırma durumunda Tablo 2.3'te gösterilen bir karmaşıklık matrisini oluşturur [79].

Tablo 2.3: İkili Sınıflandırma İçin Karmaşıklık Matrisi [79].

Veri Sınıfı	Pozitif Olarak Sınıflandırılan	Negatif Olarak Sınıflandırılan
Pozitif	Doğru Pozitif (TP)	Yanlış Negatif (FN)
Negatif	Yanlış Pozitif (FP)	Doğru Negatif (TN)

Karmaşıklık matrisi, yanlış sınıflandırmalarımızın ne kadar kötü olduğunu görmemize yardımcı olmaktadır. Bu matrisin ana köşegenindeki sayılar doğru sınıflandırmalar olurken ana köşegenden uzak sayılar hatalı sınıflandırmalardır [80].

2.12.2. Doğruluk Oranı (Accuracy)

Doğruluk oranı, model tarafından doğru şekilde sınıflandırılan test seti örneklerinin yüzdesidir. Test seti eğitim setinden bağımsızdır, aksi halde aşırı uyum (overfitting) gerçekleşir [78]. Bir Sınıflandırma modelinin doğruluk oranı toplam sınıflandırma sayısına bölünen doğru sınıflandırmaların sayısı olan genel başarı oranıdır [81]:

$$\frac{TN+TP}{TN+TP+FN+FP} \tag{2.8}$$

2.12.3. Kesinlik (Precision)

Kesinlik, verilen doğru cevapların yüzdesidir [82]. Kesinlik ölçütü, doğru pozitif olan örnek sayısının pozitif olarak tahmin edilen toplam örnek sayısına bölünmesiyle elde edilir [83].

$$Kesinlik = \frac{TP}{TP+FP} \tag{2.9}$$

2.12.4. Anma (Recall)

Anma, doğru olan olası cevapların yüzdesidir [82]. Anma ölçütü, doğru pozitiflerin sayısının doğru pozitiflerin ve yanlış negatiflerin toplamına bölünmesiyle hesaplanmaktadır [83].

$$Anma = \frac{TP}{TP+FN} \tag{2.10}$$

Kesinlik, kesinliğin veya kalitenin bir ölçütü olarak görülürken; anma bir bütünlüğün veya niceliğin ölçütüdür [78].

2.12.5. F-Ölçütü (F-Score)

F-ölçütü, kesinlik ve anmanın harmonik ortalamasıdır [84]. Bu değer 0 ile 1 arasında değer almaktadır.

$$F\text{-}Ölçütü = \frac{2 * Anma * Kesinlik}{Anma+Kesinlik} \tag{2.11}$$

2.13. LİTERATÜR İNCELEMESİ

Bu bölümde derin öğrenme yöntemleri ile yapılan metin madenciliği çalışmalarına yönelik bir literatür incelemesi sunulmuştur. Derin öğrenme modelleri kullanılarak metin madenciliği üzerine birçok çalışma yapılmış, aşağıda bu çalışmalardan birtakım örnekler bulunmaktadır.

Kim [85], cümle düzeyinde sınıflandırma problemi için yedi farklı veri kümeleri üzerinde eğitilmiş CNN ile yapılan bir dizi deney yapmıştır. Duygu veya soru sınıflandırması gerektiren yedi farklı veri seti kullanılmıştır. Önceki yapılan çalışmalarla kıyaslanarak dört veri setinde CNN en iyi sonuçları vermiştir.

Lai ve diğ. [86], çok etiketli metin sınıflandırma problemi için CNN ve RCNN isimli sinir ağı modelleri önermişlerdir. Dört farklı veri seti kullanılarak yapılan deneylerin sonuçları karşılaştırıldığında, önerilen yaklaşımların geleneksel makine öğrenme algoritmaları olan Lojistik Regresyon ve Destek Vektör Makinesi algoritmalarından daha iyi performans sergilediğini göstermiştir.

Zhang ve diğ. [87], yine metin sınıflandırma problemi için *word2vec* ve evrişimli ağların kullanımı üzerine deneysel bir model önermişlerdir. Haber makaleleri ve çevrimiçi yorumların yer aldığı büyük ölçekli sekiz farklı veri seti üzerinde çok sayıda geleneksel ve derin öğrenme modellerini uygulamışlardır. Yapılan karşılaştırmalara göre önerilen kelime tabanlı CNN'lerin metin sınıflandırma problemlerinde etkili bir yöntem olduğu ve bu yöntemin benzer problemlerin çözümünde de kullanılabileceği ifade edilmiştir.

Lee ve Dernoncourt [88], kısa-metin sınıflandırması için RNN ve CNN'e dayalı bir model sunmuşlardır. Üç farklı veri seti üzerinde uyguladıkları her iki model ile makine öğrenme algoritmalarına kıyasla başarılı sonuçlar elde etmişlerdir.

Chen ve diğ. [89], biyomedikal konulu metinlerde çok etiketli sınıflandırma için yeni ve derin bir öğrenme çerçevesi olan ML-Net'i önermişlerdir. Çalışmalarında konu ile ilgili bilimsel makalelerin özetlerini içeren iki farklı veri seti kullanmışlardır. Model, makine öğrenme ve diğer derin öğrenme yöntemleri ile karşılaştırıldığında başarılı sonuçlar elde edildiği görülmüştür.

Zhang ve Zhou [90], BP-MLL isimli geri yayılımın çok etiketli versiyonu olan bir sinir ağı algoritması önermişlerdir. Araştırma, BP-MLL'nin performansının bazı iyi tasarlanmış çok etiketli öğrenme algoritmalarından daha üstün olduğunu göstermiştir.

Johnson ve Zhang [91], metin kategorizasyonu için CNN içeren yeni bir yarı denetimli çerçeve sunmuşlardır. Film yorumlarını içeren veri seti üzerinde uygulanan model, duygu analizi ve konu sınıflandırma uygulamaları ile ilgili gerçekleştirilen önceki yaklaşımlardan daha iyi sonuçlar elde etmiştir.

Gonçalves ve diğ. [92], bilimsel makale özetlerindeki cümleleri sınıflandırmak için evrişimli bir katmana ve çift yönlü tekrarlayan birime dayalı yeni bir derin öğrenme yaklaşımı önermişlerdir. Önerilen sinir ağı, biyomedikal alandan yirmi bin özetten oluşan veri seti üzerinde test edilmiştir. En gelişmiş sinir ağına kıyasla; kesinlik, anma ve F-ölçütü değerleri için önerilen model %91 civarında başarılı bir performans göstermiştir.

Nam ve diğ. [93], büyük ölçekli çok etiketli metin sınıflandırma için basit bir sinir ağı yaklaşımı kullanmayı önermişlerdir. *ReLU, dropout* ve *AdaGrad* gibi ileri tekniklerle donatılmış basit sinir ağı modeli altı farklı veri seti üzerinde uygulamışlardır. Önerilen yaklaşımın daha önceki çalışmalarda kullanılan BP-MLL modelinden daha iyi performans gösterdiğini görmüşlerdir.

Tang ve diğ. [94], film ve restoran yorumlarını içeren dört farklı veri seti üzerinde CNN ve LSTM modelleri kullanarak duygusal sınıflandırma gerçekleştirmişlerdir. Deneysel sonuçlar, önerilen LSTM modelinin CNN modeline göre her bir veri seti için daha iyi doğruluk oranlarına sahip olduğunu göstermiştir.

Kato ve Goto [95], *Word2Vec* tekniğinin web haber metinlerini kategorilere ayırmada derin öğrenme için bir girdi olarak kullanılıp kullanılamayacağını araştırmışlardır. Metin sınıflandırma için geleneksel yöntemlerin çoğundan farklı olarak önerilen yöntemin, %78 doğruluk oranı ile daha başarılı olduğu ortaya koyulmuştur.

Kaynar ve diğ. [96], spam maillerin sınıflandırılmasında yapılan çalışmalardan farklı olarak oto-kodlayıcı tabanlı derin öğrenme yöntemi önermişlerdir. Derin öğrenme mimarisi, yığın gibi pek çok oto-kodlayıcı bağlayarak oluşturulmuştur. Oto-kodlayıcılı derin öğrenme

makinesini kullanan sınıflandırıcının, %98 doğru sınıflandırma için son derece yüksek bir başarı oranına sahip olduğu gösterilmiştir.

3. MALZEME VE YÖNTEM

3.1. PROBLEMİN TANIMI

Sürekli gelişen dünyamızda bilgi, bilginin paylaşılması ve bunun doğru bir amaca hizmet etmesi için tartışmasız her alanda teknolojik gelişmeler yaşanmaktadır. Bilgi teknolojilerindeki artış ile birlikte sağlık alanında kullanımı, mevcut sorunlara getirilen çözüm ve kolaylığın yanında bilişimden kaynaklanan başka problemler de ortaya çıkabilmektedir.

Hastane Bilgi Yönetim Sistemi (HBYS); hastanelerdeki tıbbi ve idari iş süreçlerinde işlemlerin bilgisayar aracılığıyla gerçekleştirilmesi, bu süreçlerde oluşturulan her çeşit verinin farklı kullanıcılar vasıtasıyla, birbirleri ile bütünleşik şekilde işlem gören modüller tarafından ortak bir ana veri tabanına kaydedilmesi, kaydedilen verilere gerektiğinde bu veri tabanından anlamlı bir biçimde alınmalarını sağlayan, hastanelere zaman, iş gücü ve maddi kazanım ile beraber muhtemelen en önemlisi düzgün ve güvenilir istatistiksel verileri sağlayan yazılımlar bütünü şeklinde tanımlanmaktadır [97].

Finansal, tıbbi ve idari birimlerin altında HBYS'de bulunan bazı modüller aşağıda gösterilmektedir.

Finansal Modüller: Hasta Kayıt Kabul Modülü, Randevu Modülü, Evrak Kayıt ve Takip Modülü, Vezne Modülü, Fatura Modülü, Performans Yönetim Ek Ödeme Modülü.

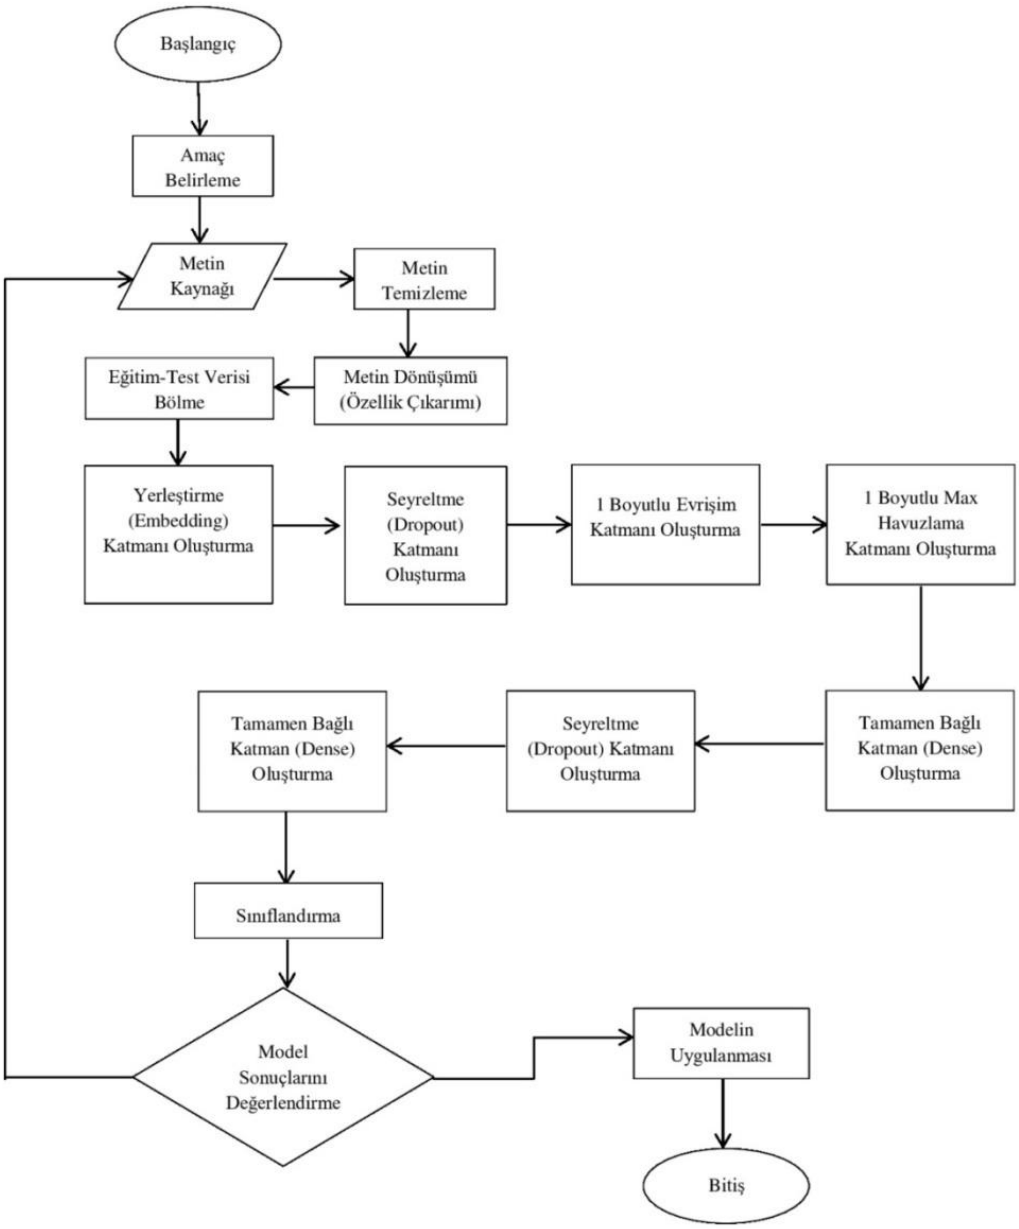
Medikal Modüller: Hasta Yatış Modülü, Yatan Hasta Servis Modülü, Eczane Modülü, Laboratuvar Modülü, Radyoloji Modülü, Kan Bankası Modülü.

İdari Modüller: Muhasebe Modülü, Satın alma Modülü, Demirbaş Modülü, İnsan Kaynakları Yönetim Modülü, Cihaz ve Arıza Takip Modülü.

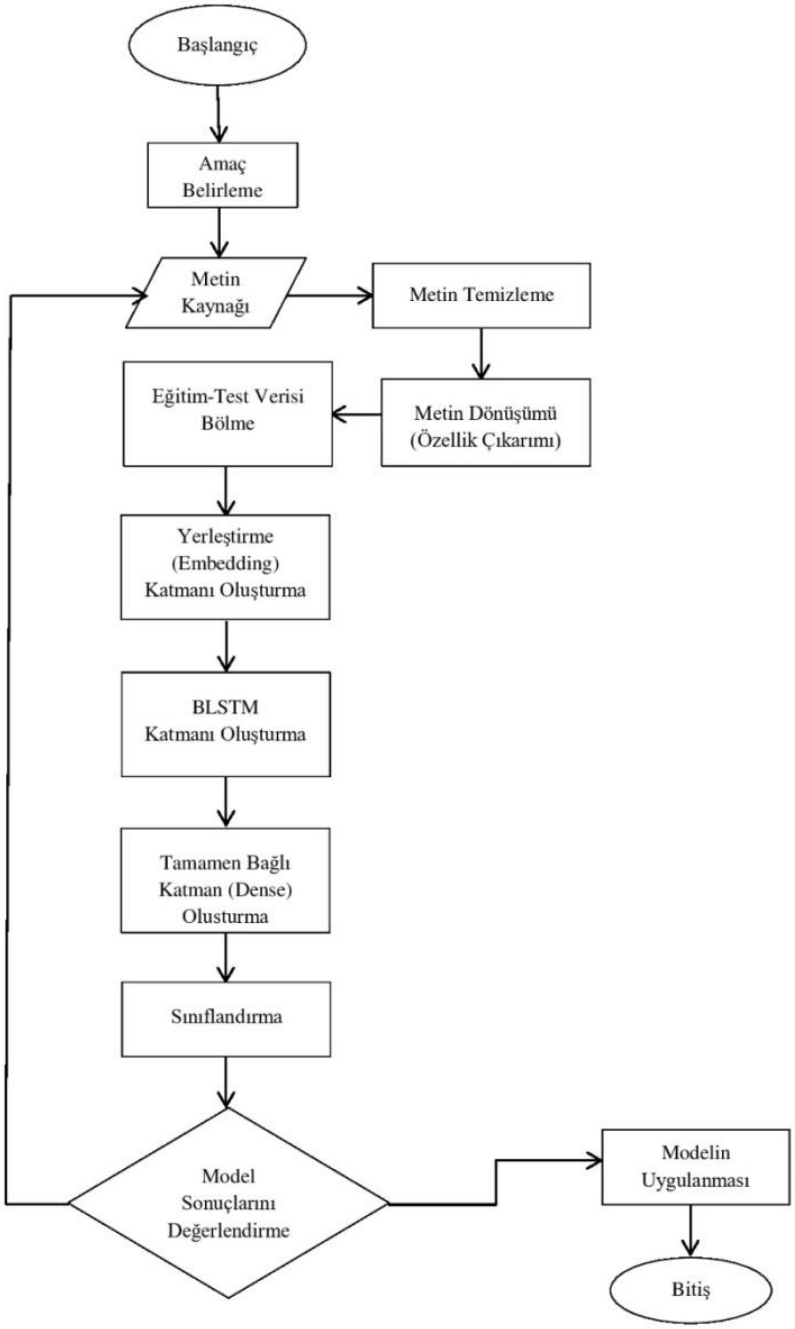
HBYS, içinde birden fazla yazılım ve veri tabanı bulunduran, çok modüllü ve entegre bir yapıda çalışan sistemler olduğundan hastane kullanıcıları yaptığı işlemlerde birçok sorunla karşı karşıya kalabilmektedir. Dolayısıyla projenin test aşamasında sisteme düşen metin halindeki problemler veri tabanında metinler halinde, modüllerine göre kategorize edilmiş

biçimde saklanmaktadır. Sınıflandırma işlemi el ile yapıldığından binlerce sorun için bu işlemin yapılması çok fazla zaman almaktadır. Bu probleme çözüm olarak, metin madenciliği ve derin öğrenme yöntemleri kullanılarak CNN ve BLSTM modelleri geliştirilmiştir. Geliştirilen model ile biriken binlerce problemin sınıflandırma işleminin otomatik olarak yapılması sağlanmıştır.

Çalışmada CNN ve BLSTM modelleri için uygulanan adımları gösteren akış şemaları Şekil 3.1 ve Şekil 3.2'de sırasıyla gösterilmektedir.



Şekil 3.1: CNN Modeli Akış Şeması.



Şekil 3.2: BLSTM Ağı Modeli Akış Şeması.

3.2. VERİ SETİ

HBYS projesinin test aşamasındaki yazılımsal problemleri metin olarak sisteme düşmektedir ve bunlar proje ile ilgilenen ekip tarafından kategorize edilmektedir.

Uygulamada kullanılan veri seti hastane otomasyon sisteminde ortaya çıkan problemlerden oluşmaktadır. En çok problemin meydana geldiği toplamda üç kategoriden oluşan veri setindeki metin sayısı 1120 adettir. Bu kategorilerden 459 adedi Klinik İşlemleri, 311 adedi Laboratuvar ve 350 adedi Faturalama/Medula kategorisine aittir.

3.3. DERİN ÖĞRENME ALGORİTMALARININ UYGULANMASI

Veri setini derin öğrenme algoritmaları ile çalışmaya hazır hale getirmek için kullanacağımız metni temizlemek ve uygun formata dönüştürmek gerekir. Önişleme adımında ilk olarak, metindeki tüm kelimeler küçük harfe dönüştürülmüştür. Noktalama işaretleri ve Türkçe dilinde sıklıkla kullanılan gereksiz kelimeler metinden kaldırılmıştır. Örneğin “ile”, “bir”, “ve”, “veya” bu kelimelerden bazılarıdır. Daha sonra tokenizasyon (tokenization) işlemi yapılmıştır. Literatürde tokenlere ayırma ismiyle de bahsedilen bu işlem bir metni belirteçlere (dizgelere) böler. Belirteç cümle, kelime veya harf olabilir.

Bu uygulamada metin kelimelere ayrılarak bir sözlük oluşturulmuştur. Kelimeler daha sonra sayı olarak temsil edilebilir ve böylece derin öğrenme için özellik vektörleri olarak kullanılabilirler. Kelimelerin vektörlerle temsil edilmesi için kelime yerleştirme (word embedding) yöntemi kullanılmıştır. En sık kullanılan maksimum kelime sayısı 1000 olarak alınmıştır. Her problem için maksimum kelime sayısı (dizi uzunluğu) ise 50 kelimeyle sınırlandırılmıştır. Daha sonra metinleri sınıflandırmada başarılı performans gösteren CNN ve çift yönlü LSTM (BLSTM) ağı modelleri geliştirilmiştir.

Bir derin öğrenme modelinde veri kümesi eğitim verisi ve test verisi olarak ikiye ayrılmaktadır. Eğitim verisinde sınıflar bellidir ve öğrenme işlemi eğitim verisi ile gerçekleşir. Test verisinde sınıflar belli değildir ve model eğitim verisinden öğrendiği bilgilerle test verisinin sınıflarını tahmin eder. Derin öğrenme algoritmalarının başarısını farklı eğitim ve test verilerinin sayılarına göre karşılaştırabilmek için; veri setini %90 eğitim-%10 test, %80 eğitim-%20 test ve %67 eğitim-%33 test olarak üç ayrı bölme yöntemi ile model

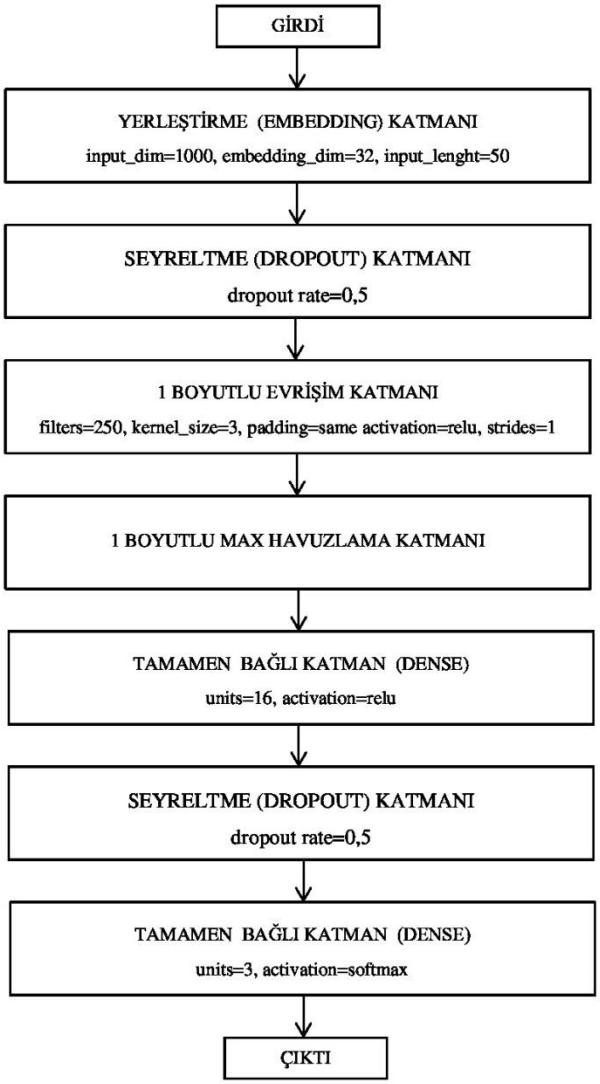
uygulanmıştır. Önerilen modellerin uygulanması Python 3.6 programlama dili kullanılarak Tensorflow arka planlı Keras 2.2.4 versiyonunda gerçekleştirilmiştir.

3.3.1. CNN Algoritmasının Uygulanması

CNN'lerin derin öğrenme için kullanılması, üç önemli faktör nedeniyle giderek daha popüler hale gelmiştir [34].

- CNN'ler manuel özellik çıkarma gereksinimini ortadan kaldırır; özellikler doğrudan CNN tarafından öğrenilir.
- CNN'ler en gelişmiş tanıma sonuçlarını üretir.
- CNN'ler yeni tanıma görevleri için yeniden eğitilebilir ve önceden var olan ağların kurulmasına olanak sağlar.

Önerilen CNN modelinde; kelime yerleştirmeleri için bir yerleştirme (embedding) katmanı, bir seyreltme (dropout) katmanı, 1 boyutlu evrişim (convolution) katmanı, 1 boyutlu maksimum havuzlama (pooling) katmanı, bir tamamen bağlı katman (gizli katman), bir seyreltme (dropout) katmanı ve çıktı için bir tamamen bağlı katman kullanılmıştır. Modelin katmanları parametre değerleri ile birlikte Şekil 3.3’te gösterilmektedir.



Şekil 3.3: CNN Modelinin Katmanları.

Derin öğrenme yöntemlerinde öğrenme işlemi temel olarak bir optimizasyon problemidir. Modeldeki ağırlıkların doğru bir şekilde güncellenmesi öğrenme işlemi için oldukça önemlidir. Hata hesaplandıktan sonra elde edilen hataya göre ağırlıklar güncellenmektedir. Ağırlıkların güncellenmesi için *Geri Yayılım Algoritması (Back-Propagation)* kullanılmaktadır. Geri yayılım algoritması ile sinir ağındaki her bir ağırlığın, hesaplanan hataya olan etkisinin hesaplanması için optimizasyon metotları kullanılmaktadır. Bu doğrultuda kullanılan bazı optimizasyon algoritmaları; *stokastik gradyan alçalış (stochastic gradient descent-SGD), rmsprop, adagrad, adadelta, adam*'dır. [98].

Eğitim sırasında gerçekleşen öğrenmede hesaplanan hatanın ne kadarının geri yansıtılacağına *öğrenme oranı (learning rate)* olarak adlandırılan bir sabit değer etki etmektedir. 0 ile 1 arasında değişen öğrenme oranı sinir ağlarının eğitiminde kullanılan bir hiperparametredir.

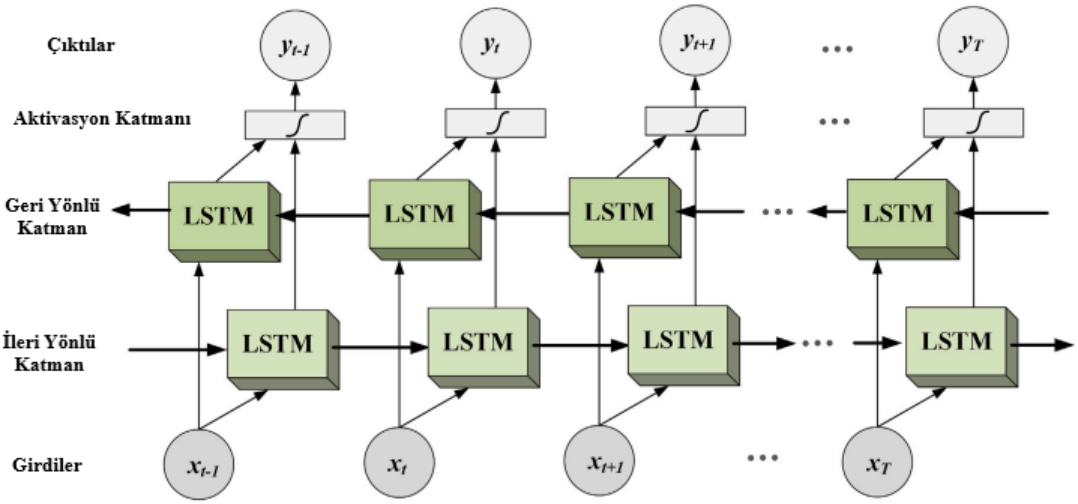
Derin öğrenme yaklaşımlarında çok katmanlı sinir ağlarının nasıl tasarlanacağı, kaç katmandan oluşacağı, bu katmanların kaç nöron içereceği, hangi optimizasyon algoritmasının veya hangi aktivasyon fonksiyonlarının kullanılacağı oldukça önemlidir. Bu amaçlara yönelik çok katmanlı ağ yapılarının, en iyi şekilde tasarlanması için optimum parametrelerle modellenmesi gerekmektedir. Bu doğrultuda çalışmada önerilen her iki sınıflandırma modelinin parametre değerleri *ızgara araması (grid search)* yaklaşımı ile en iyilenmiştir. Bu doğrultuda doğruluk oranı en yüksek olan parametre değerleri ile devam edilmiştir.

Önerilen CNN modelinde parametre optimizasyonu doğrultusunda *adam* algoritması optimizasyon algoritması olarak seçilmiştir. Aynı şekilde gizli katmandaki nöron sayısı 16, dropout oranı 0,5 ve öğrenme oranı (learning rate) ise 0,001 olarak ayarlanmıştır.

3.3.2. BLSTM Ağı Algoritmasının Uygulanması

Çift yönlü bir RNN (BRNN), geleneksel RNN'lerden çeşitli kısıtlamaları kaldırmak için önerilen bir modeldir. Bu model düzenli RNN nöron durumlarını ileri ve geri olarak ayırmaktadır. Başka bir deyişle, ileri ve geri olmak üzere iki farklı tekrarlayan ağ vardır. Bu iki ağ, çıktı bilgisi üretmek için aynı çıktı katmanına bağlanır. Bu yapı ile bir zaman dilimi içinde sıralı girdilerin hem geçmiş hem de gelecekteki durumları gecikmeden değerlendirilebilmektedir.

BRNN yapısının LSTM sürümüne Çift Yönlü LSTM (Bidirectional Long Short-Term Memory – BLSTM) adı verilir. Bu versiyon, sınıflandırma işlemlerinde LSTM model performansını arttırmaktadır. Standart LSTM yapısından farklı olarak, BLSTM mimarisindeki sıralı girişler için iki farklı LSTM ağı eğitilmiştir. Şekil 3.4, sıralı girişlerde çalışan temel bir BLSTM yapısını göstermektedir [99].



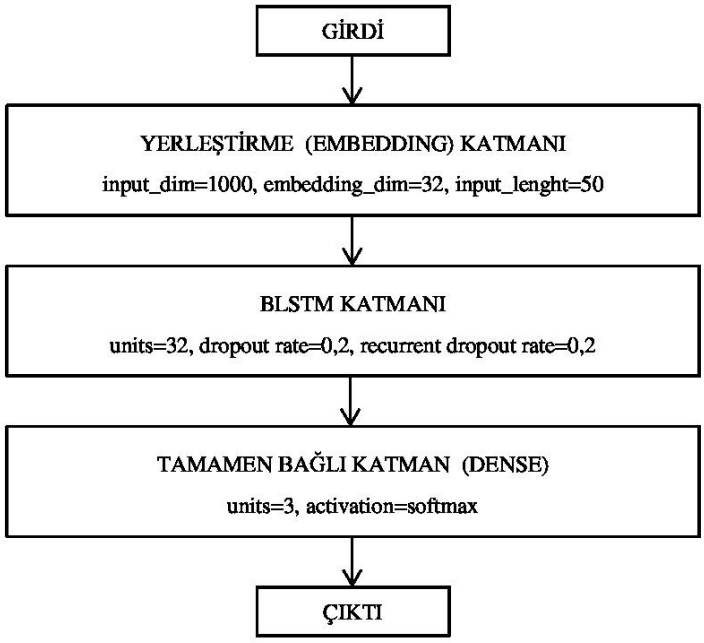
Şekil 3.4: BLSTM Ağının Temel Yapısı [99].

BLSTM'ler uzun vadeli bağımlılıkları öğrenme yeteneğine sahiptirler ve aynı zamanda geçmiş ve gelecekten gelen bağlamsal özellikleri koruyabilirler. Şekil 3.4'te gösterildiği gibi, aynı çıkış katmanına ilerleyen iki ayrı gizli katman içerirler [100]. Yani *t* anındaki h_t çıktısı, *t* ve *t*'den önceki girdilerle ilişkili olarak değer alır. *t* anındaki sistem çıktısının *t*'den sonraki girdiler ile bağımlılığının olması durumunda RNN yapıları ve LSTM yapıları bu bağımlılıkların çözümlenmesini gerçekleştirememektedir. Metinlerle yapılan çalışmalarda ise cümle içinde bir kelimenin işlevine bazı zamanlarda daha sonraki kelimelerin bilgilerine bağlı olarak karar verilmesi gerekebilmektedir. Bu *t* anındaki h_t çıktısını *t* anından sonraki girdiler ile de ilişkilendirilmesi gerektiği anlamına gelmektedir. Bu tür problemlerin çözümünde BLSTM yapıları kullanılmaktadır. BLSTM temel olarak iki adet LSTM yapısının veriyi normal sırada ve ters sırada işleme alması ve sonuçları birleştirmesi ilkesi ile çalışmaktadır [101].

Sekil 3.4'te gösterildiği gibi y_t sistem çıktısı ileri yönlü LSTM çıktısı $\vec{h}_t$ ve geri yönlü LSTM çıktısı $\overleftarrow{h}_t$ işaretlerinin birleşiminden oluşmaktadır.

$$y_t = \vec{h}_t + \overleftarrow{h}_t \tag{3.1}$$

Dolayısıyla metinlerde başarılı performans gösteren çift yönlü bir LSTM ağı modeli, metin sınıflandırma problemimizde kullanmak üzere önerilmiştir. Önerilen BLSTM modelinde; bir yerleştirme (embedding) katmanı, bir çift yönlü LSTM katmanı ve çıktı için bir tamamen bağlı katman kullanılmıştır. Modelin katmanları parametre değerleri ile birlikte Şekil 3.5'te gösterilmektedir.



Şekil 3.5: BLSTM Modelinin Katmanları.

Önerilen bu modelde parametre optimizasyonu doğrultusunda dropout oranı 0,2 ve optimizasyon algoritması *adam* algoritması seçilmiştir. Öğrenme oranı (learning rate) ise 0,01 olarak ayarlanmıştır.

4. BULGULAR

Bu bölümde en iyilenmiş parametre değerleri ile uygulanan iki modelin, sırasıyla %90 eğitim-%10 test, %80 eğitim-%20 test ve %67 eğitim-%33 test bölme yöntemleri ile eğitim ve test verileri oluşturulmuş veri seti için performans analizi sonuçları sunulmuştur.

%90 eğitim-%10 test bölme yöntemi ile eğitim ve test verileri oluşturulmuş veri seti için her iki modelin performans ölçütleri açısından değerlendirmeleri aşağıdaki tabloda gösterilmektedir.

Tablo 4.1: Derin Öğrenme Modellerinin Performans Analizi (%90 Eğitim-%10 Test).

Algoritmalar	**Doğruluk Oranı**	**Kesinlik**	**Anma**	**F-Ölçütü**
CNN	0,9017	0,9066	0,8976	0,8998
BLSTM	0,9196	0,9187	0,9248	0,9209

Tablo 4.1'e göre 0,9196 değeri ile en iyi doğruluk oranına sahip olan BLSTM modelinin uygulanmasında 3 kategori arasında farklılık gösteren 112 problem verisinden 103 tanesi doğru şekilde sınıflandırılmıştır. Diğer performans ölçütleri açısından incelendiğinde; sırasıyla kesinlik, anma ve F-ölçütü değerleri sırasıyla 0,9187, 0,9248 ve 0,9209 olan BLSTM modeli, CNN modeline göre en iyi performansı sergilemiştir.

%80 eğitim-%20 test bölme yöntemi ile eğitim ve test verileri oluşturulmuş veri seti için her iki modelin performans ölçütleri açısından değerlendirmeleri Tablo 4.2'de gösterilmiştir.

Tablo 4.2: Derin Öğrenme Modellerinin Performans Analizi (%80 Eğitim-%20 Test).

Algoritmalar	**Doğruluk Oranı**	**Kesinlik**	**Anma**	**F-Ölçütü**
CNN	0,8883	0,8829	0,8902	0,8862
BLSTM	0,9017	0,9021	0,9031	0,9016

Tablo 4.2'ye göre 0,9017 değeri ile en iyi doğruluk oranına sahip olan BLSTM modelinin uygulanmasında, 3 kategori arasında farklılık gösteren 224 problemden 202 tanesi doğru şekilde sınıflandırılmıştır. Diğer performans ölçütleri açısından incelendiğinde; sırasıyla kesinlik, anma ve F-ölçütü değerleri sırasıyla 0,9021, 0,9031 ve 0,9016 olan BLSTM modeli, CNN modeline göre en iyi performansı sergilemiştir.

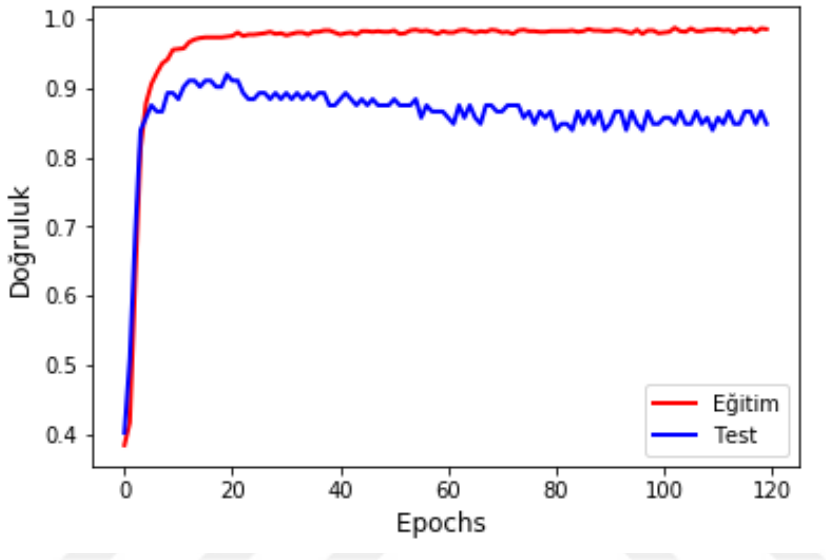
%67 eğitim-%33 test bölme yöntemi ile eğitim ve test verileri oluşturulmuş veri seti için her iki modelin performans ölçütleri açısından değerlendirmeleri Tablo 4.3'te gösterilmiştir.

Tablo 4.3: Derin Öğrenme Modellerinin Performans Analizi (%67 Eğitim-%33 Test).

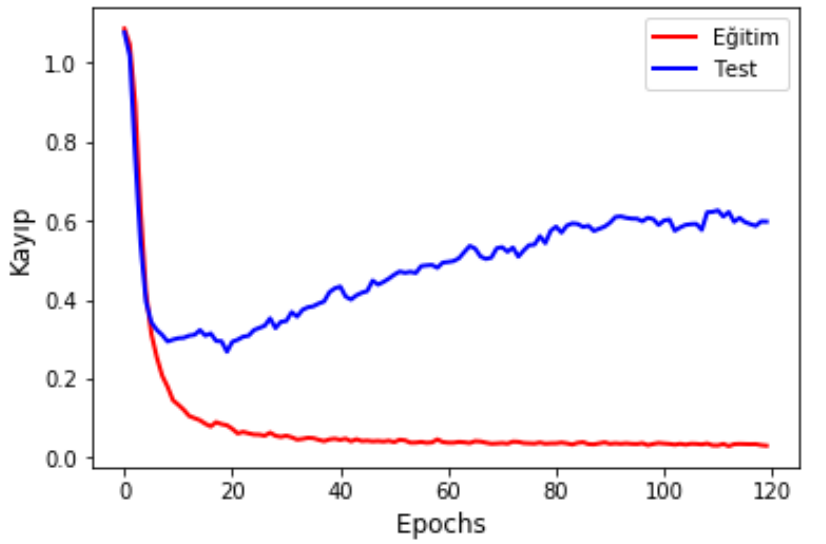
Algoritmalar	**Doğruluk Oranı**	**Kesinlik**	**Anma**	**F-Ölçütü**
CNN	0,8108	0,8109	0,8143	0,8122
BLSTM	0,8270	0,8275	0,8220	0,8243

Tablo 4.3'e göre 0,8270 değeri ile en iyi doğruluk oranına sahip olan BLSTM modelinin uygulanmasında, 3 kategori arasında farklılık gösteren 370 problem verisinden 306 tanesi doğru tahmin edilmiştir Diğer performans ölçütleri açısından incelendiğinde; kesinlik, anma ve F-ölçütü değerleri sırasıyla 0,8275, 0,8220 ve 0,8243 olan BLSTM modeli, CNN modeline göre en iyi performansı sergilemiştir.

Yapılan karşılaştırmalara göre en iyi performans değerlerine sahip model olan, %90 eğitim - %10 test bölme yöntemi ile eğitim ve test verileri oluşturulmuş veri seti için uygulanmış BLSTM modelinin eğitim ve test verisi açısından doğruluk ve kayıp oranlarının grafikleri aşağıda gösterilmektedir.



Şekil 4.1: BLSTM Modeli Eğitim ve Test Verisi Doğruluk Oranı Grafiği (%90 Eğitim-%10 Test).



Şekil 4.2: BLSTM Modeli Eğitim ve Test Verisi Kayıp Oranı Grafiği (%90 Eğitim-%10 Test).

BLSTM modelinde en iyi performansı gösteren %90 eğitim-%10 test bölme yöntemi ile eğitim ve test verileri oluşturulmuş veri seti için epoch süresi boyunca kayıp oranı ve doğruluk oranı değişimi grafiklerde gösterildiği gibidir. Buradan anlaşılacağı üzere bu oranlar tüm veri kümeleri boyunca tutarlı bir şekilde değişim göstermiştir. Aynı şekilde diğer bölme yöntemlerine göre uygulanan modellerin grafikleri de tutarlı bir değişim göstermektedir ve doğruluk oranı açısından oldukça başarılı sonuçlar elde edilmiştir.



Şekil 4.3: BLSTM Modeli Karmaşıklık Matrisi (%90 Eğitim-%10 Test).

Şekil 4.3'te gösterilen BLSTM modelinin karmaşıklık matrisine göre yeşil renkte olan köşegendeki sayılar doğru tahmin edilen kategorilerin sayısını belirtmektedir. Gerçekte 32 adet olduğu test edilen Faturalama/Medula kategorisinin 32 tanesi de doğru tahmin edilmiştir. Gerçekte 45 adet olduğu test edilen Klinik İşlemleri kategorisinin doğru tahmin edilme sayısı

40 iken, bu sınıfın 2 tanesi Faturalama/Medula kategorisi olarak tahmin edilmiş ve 3 tanesi de Laboratuvar kategorisi olarak tahmin edilmiştir. Aynı şekilde 35 adet olduğu test edilen Laboratuvar kategorisinin 31 tanesi doğru tahmin edilirken, 1 tanesi Faturalama/Medula kategorisi olarak ve 3 tanesi de Klinik İşlemleri kategorisi olarak tahmin edilmiştir.

5. TARTIŞMA VE SONUÇ

Hastane Bilgi Yönetim Sistemi yazılımlarını geliştirme ve kullanım aşamasında birçok problemle karşılaşılmaktadır ve bu problemlerin çözümünde harcanan zaman hastanın bakım ve tedavi sürecini, hastane yönetim faaliyetlerini, dolayısıyla tüm süreci yavaşlatmaktadır. Bu sebeple HBYS projesinin test aşamasında ortaya çıkan problemlerin yapay zekâ destekli bir model ile otomatik olarak sınıflandırılması daha sonra oluşacak kullanıcı problemlerinin de kategorize edilerek hızlı ve etkili çözümlere ulaşılması sağlanmalıdır. İşin uzmanı tarafından yapıldığı varsayılsa bile binlerce sorunun kategorize edilme işleminin manuel olarak gerçekleştirilmesi zaman alan ve zahmetli bir iştir.

Bu çalışmada amaçlanan, yazılım projelerinin hem test aşamasında proje ekibinin hem de kullanım aşamasında kullanıcıların karşılaştığı binlerce problemi hızlı ve kolay yoldan kategorize ederek çözümler için bir altyapı oluşturmaktır. Bu doğrultuda kullanıcılar ve yazılımcıların karşılaştığı ve tanımladığı problemlerin yapay zekâ destekli bir model ile otomatik olarak belirli kategorilere atanması önem kazanmaktadır.

Tez kapsamında geliştirilen CNN ve BLSTM modelleri sayesinde HBYS projesinin problemlerinden oluşan verilerin sınıflandırılmasında oldukça başarılı sonuçlar elde edilmiştir. Yapılan karşılaştırmalara göre 0,9196 olan doğruluk oranının yanı sıra kesinlik, anma ve F-ölçütü değerlerine bakıldığında da en yüksek başarıyı metin işlemede daha iyi sonuçlar veren BLSTM modeli göstermiştir. Geliştirilen model yaklaşık olarak %92 oranında gelen problemleri doğru kategorilere atayacaktır. Elde edilen bu sonuçlara göre problemlerin sınıflandırılmasında başarılı sonuçlar veren BLSTM modelinin kullanılması uygun görülmüştür.

Önerilen yaklaşım ile biriken binlerce problemin sınıflandırma işlemi otomatik şekilde yapılıp anlık olarak problemle ilgilenecek kişi veya departmanlara iletilmesi sağlanmaktadır. HBYS projesinin test aşamasında ortaya çıkan problemleri kategorize eden model test aşamasından sonra kullanım sırasında meydana gelen problemleri de kategorize ederek kullanıcılara hızlı bir çözüm sunulacaktır.

BLSTM modellerinin performansları kendi arasında bölme yöntemlerine göre karşılaştırıldığında; %90 eğitim-%10 test bölme yöntemi ile eğitim ve test verileri oluşturulmuş veri seti için uygulanan BLSTM modeli ile diğer bölme yöntemlerine göre daha yüksek başarı oranı elde edilmiştir. CNN modellerinin performansları kendi arasında bölme yöntemlerine göre karşılaştırıldığında; %90 eğitim-%10 test bölme yöntemi ile eğitim ve test verileri oluşturulmuş veri seti için uygulanan CNN modeli ile diğer bölme yöntemlerine göre daha yüksek başarı oranı elde edilmiştir. Eğitim ve test verisini bölme yöntemlerinin önerilen modellerin performansları üzerindeki etkisi incelenecek olursa; kullanılan bölme yöntemlerinde eğitim seti arttıkça her iki model için de tahmin performansının iyi yönde arttığı gözlemlenmiştir. Bu sonuç göstermektedir ki veri seti genişledikçe geliştirilen model çok daha iyi eğitilebilecek ve doğruluk oranı artacaktır.

En iyi performans değerlerine sahip olan BLSTM modelinin karmaşıklık matrisinin sonuçlarına göre Klinik İşlemleri kategorisine sahip problemler tahmin edilirken, bu kategori daha çok Laboratuvar kategorisi ile karışmıştır. Aynı şekilde Laboratuvar kategorisine sahip problemler tahmin edilirken, bu kategori daha çok Klinik İşlemleri kategorisi ile karışmıştır. Dolayısıyla bu soruna çözüm olarak çok karıştırılan kategoriye ait veri sayısı arttırılmalıdır.

Sağlık sektörüne yönelik yazılım projelerinde uygulanan ilk çalışma olma özelliğinden dolayı bu tez çalışması ile literatüre katkı sağlanmıştır. Aynı zamanda sadece yazılım projelerinde değil tüm projelerdeki problemler için uygulanabilir bir model geliştirilmiştir.

Gelecekteki çalışmalar için tüm kategorilerin dahil edildiği daha fazla veri kullanılarak farklı derin öğrenme modelleri ile sonuçlar arttırılabilir.

KAYNAKLAR

[1]. Han, J., Kamber, M. ve Pei, J., 2011, *Data Mining: Concepts and Techniques*, Morgan Kaufmann Publishers, USA, ISBN: 978-0-12-381479-1.

[2]. Feldman, R. Ve Sanger, J., 2007, *The Text Mining Handbook: Anvenced Approaches in Analyzing Unstructured Data*, Cambridge University Press, New York, ISBN: 978-0-511-33507-5.

[3]. Barutçugil, İ., 2002, *Bilgi Yönetimi*, Kariyer Yayıncılık, İstanbul, ISBN: 0975-8515-26-8.

[4]. Bergeron, B., 2003, *ESSENTIALS of Knowledge Management*, John Wiley & Sons, Canada, ISBN: 0-471-28113-1.

[5]. Tiwana, A., 1999, *The Knowledge Management Toolkit*, Prentice Hall PTR, ISBN: 0-13-012853-8.

[6] Davenport, T.H. ve Prusak, L., 1998, *Working Knowledge: How Organizations Manage What They Know*, Harvard Business School Press, Boston, ISBN: 978-0585056562.

[7]. McCampbell, A.S., Clare, L.M. ve Gitters, S.H., 1999, Knowledge Management: The New Challenge for The 21st Century, *Journal of Knowledge Management*, 3 (3), 172-179.

[8]. Namlı, E., 2005, *İnşaat Proje Yönetiminde Faaliyet Esaslı Bilgi Yönetim Modeli*, Yüksek Lisans Tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü.

[9]. Nonaka, I, Krogh, G.V. ve Ichijo, K., 2000, *Enabling Knowledge Creation*, Oxford University Press, New York, ISBN: 975-8296-51-5.

[10]. O'dell, C. ve Essaides, N., 1998, *If Only We Knew What We Know*, The Free Press, ISBN: 975-8296-48-5.

[11]. Rao, M., *Knowledge Management Tools and Techniques: Practitioners and Experts Evaluate KM Solutions*, Butterworth-Heinemann, Oxford, ISBN: 0-7506-7818-6.

[12]. Stankosky, M., 2005, *Creating the Discipline of Knowledge Management The Latest in University Research*, Butterworth-Heinemann, Oxford, ISBN: 0-7506-7878-X.

[13]. Davenport, T.H., 1997, Ten Principles of Knowledge Management and Four Case Studies, *Knowledge and Process Management*, 4 (3), 187-208.

[14] Sarkar, D., Bali, R. ve Ghosh, T., 2018, *Hands-On Transfer Learning with Python*, Packt Publishing Ltd., Birmingham, ISBN: 978-1-78883-130-7.

[15] Chollet, F., 2017, *Deep Learning with Python*, Manning Publications Co., Shelter Island, ISBN: 978-1-61729-443-3.

[16]. Datai Team, 2018, *Deep Learning Tutorial for Beginners*, https://www.kaggle.com/kanncaa1/deep-learning-tutorial-for-beginners, [Ziyaret Tarihi: 1 Mart 2019].

[17] Pattanayak, S., 2017, *Pro Deep Learning with TensorFlow: A Mathematical Approach to Advanced Artificial Intelligence in Python*, Apress, ISBN: 978-1-4842-3096-1.

[18] Şeker, Ş.E., 2008, *Sinir Hücresi (Nöron, Neuron)*, http://bilgisayarkavramlari.sadievrenseker.com/2008/10/02/sinir-hucresi-noron-neuron/, [Ziyaret Tarihi: 1 Mart 2019].

[19]. MathWorks, 2017b, *Introducing Deep Learning with MATLAB*, https://www.mathworks.com/content/dam/mathworks/tag-team/Objects/d/80879v00_Deep_Learning_ebook.pdf, [Ziyaret Tarihi: 1 Mart 2019].

[20]. MathWorks, 2017a, *What Is Deep Learning? 3 Things You Need To Know*, https://www.mathworks.com/discovery/deep-learning.html, [Ziyaret Tarihi: 1 Mart 2019].

[21]. McCulloch, W. S. ve Pitts, W., 1943. A Logical Calculus of the Idea Immanent in Nervous Activity, *Bulletin of Mathematical Biophysics*, 5, 115-133.

[22]. Ivakhnenko, A.G. ve Lapa, V.G., 1965, *Cybernetic predicting devices*, N.Y. CCM Information Corp., New York.

[23]. Fukushima, K., 1988, Neocognitron: A hierarchical neural network capable of visual pattern recognition, *Neural Networks*, 1 (2), 119-130.

[24]. Weng, J., Cohan, P. ve Herniou, M., 1992, Camera Calibration with Distortion Models and Accuracy Evaluation, *IEEE Transactions On Pattern Analysis and Machine Intelligence*, 14 (10), 965-980.

[25]. Cortes, C. ve Vapnik, V., 1995, Support-Vector Networks, *Machine Learning*, 20 (3), 273–297.

[26]. Hochreiter, S. ve Schmidhuber, J., 1997, Long Short-Term Memory, *Neural Computation*, 9 (8), 1735-1780.

[27]. Hinton, G.E. VE Salakhutdinov, R., 2006, Reducing the Dimensionality of Data with Neural Networks, *Science*, 313 (5786), 504-507.

[28]. Kayaalp, K. ve Süzen, A.A., 2018, *Derin Öğrenme ve Türkiye'deki Uygulamaları*, Iksad Publications, Türkiye, ISBN 978-605-7510-53-2.

[29]. Hubel, D.H. ve Wiesel, T.N., 1959, Receptive fields of single neurons in the cat's striate cortex, *Journal of Physiology*, 148 (3), 574-591.

[30]. Hubel, D.H. ve Wiesel, T. N., 1962, Receptive Fields, Binocular Interaction and Functional Architecture in the Cat's Visual Cortex, *Journal of Physiology*, 160 (1), 106-154.

[31]. Hubel, D.H. ve Wiesel, T., 1968, Receptive fields and functional architecture of monkey striate cortex, *Journal of Physiology*, 195, 215-243.

[32]. Goodfellow, I., Bengio, Y. ve Courville, A., 2016, *Deep Learning*, The Mit Press, ISBN: 0262035618.

[33]. Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J. ve Chen, T., 2018, Recent Advances in Convolutional Neural Networks, *Pattern Recognition*, 77, 354-377.

[34]. MathWorks, 2017, *Convolutional Neural Network: 3 Things You Need to Know*, https://www.mathworks.com/solutions/deep-learning/convolutional-neural-network.html, [Ziyaret Tarihi: 2 Mart 2019].

[35]. Ranganathan, S., Gribskov, M.R. ve Nakai, K., 2019, *Encyclopedia of Bioinformatics and Computational Biology*, Elsevier Science Publishing Co., ISBN: 978-012-811414-8.

[36]. Le Cun, Y., Bengio, Y. ve Hinton, G., 2015, Deep Learning, *Nature*, 521, 436–444.

[37]. Deniz, E., Şengür, A. ve Kadiroğlu, Z., 2018, Transfer Learning Based Histopathologic Image Classification for Breast Cancer Detection, *Health Information Science and Systems*, 6 (18), 1-7.

[38]. A. Gibson ve J. Patterson, 2016, *Deep Learning: A Practitioner's Approach*, O'Reilly Media, Sebastopol, ISBN: 978-1-4919-1425-0.

[39]. Hu, W., Huang, Y., Li, W., Zhang, F.R., ve Li, H., 2015, Deep Convolutional Neural Networks for Hyperspectral Image Classification, *Journal of Sensors*, 2015, 2.

[40]. Olah, C., 2014, *Conv Nets: A Modular Perspective*, http://colah.github.io/posts/2014-07-Conv-Nets-Modular/, [Ziyaret Tarihi: 5 Mart 2019].

[41]. Dertat, A., 2017, *Applied Deep Learning-Part 4: Convolutional Neural Networks*, https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2, [Ziyaret Tarihi: 5 Mart 2019].

[42]. Kuş, Z., 2018, *Konvolüsyonel Sinir Ağları ve Uygulamaları,* Yüksek Lisans Tezi, Fatih Sultan Mehmet Vakıf Üniversitesi Mühendislik ve Fen Bilimleri Enstitüsü.

[43]. Karakuş, B.A., *Derin Öğrenme ve Büyük Veri Yaklaşımları ile Metin Analizi*, Doktora Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü.

[44]. Bora, K., 2017, *Yapay Sinir Ağları*, https://github.com/kemalcanbora/keras_turkish_doc/blob/master/keras_dok%C3%BCmantasyon.pdf, [Ziyaret Tarihi: 6 Mart 2019].

[45]. Serengil, Ş.İ., 2017, *A Gentle Introduction to Convolutional Neural Networks*, http://sefiks.com/2017/11/03/a-gentle-introduction-to-convolutional-neural-networks/, [Ziyaret Tarihi: 6 Mart 2019].

[46]. Işık, G. ve Artuner, H., 2016, Recognition of radio signals with deep learning Neural Networks, *24th Signal Processing and Communication Application Conference (SIU)*, 16-19 May 2016 Zonguldak, IEEE, ISBN: 978-1-5090-1679-2, 837-840.

[47]. Doğan, F. ve Türkoğlu, İ., 2018, Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması, *Sakarya Unıversıty Journal Of Computer And Informatıon Scıences,* 1 (1), 10-21.

[48]. Srivastava, N., Hinton, G.E., Krizhevsky, A., Sutskever, I. ve Salakhutdinov, R., 2014, Dropout: A Simple Way to Prevent Neural Networks From Overfitting, *Journal of Machine Learning Research*, 15, 1929-1958.

[49]. Olah, C., 2015, *Understanding LSTM Networks*, http://colah.github.io/posts/2015-08-Understanding-LSTMs/, [Ziyaret Tarihi: 6 Mart 2019].

[50]. Alp, E.C., 2018, *Recurrent Neural Network*, http://elitcenkalp.blogspot.com/2018/04/recurrent-neural-network.html, [Ziyaret Tarihi: 6 Mart 2019].

[51]. Hochreiter, S. ve Schmidhuber, J., 1997, Long Short-Term Memory, *Neural Computation,* 9 (8), 1735-1780.

[52]. Liu, G. ve Guo, J., 2019, Bidirectional LSTM with attention mechanism and convolutional layer for text classification, *Neurocomputing,* 337, 325-338.

[53]. Salakhutdinov, R. ve Hinton, G.E., 2009, Deep Boltzmann Machines, *Proceeding of the 12th International Conference on Artificial Intelligence and Statistics*, 8-12 June 2009 Barcelona, Spain, ACM Press, ISBN:978-1-60558-597-0, 448-455.

[54]. Hinton, G.E., Dayan, P. ve Revow, M., 1997, Modeling the Manifolds of Images of Handwritten Digits, *IEEE Transactions on Neural Networks,* 8 (1), 65-74.

[55]. Tan, C.C. ve Eswaran, C., 2008, Performance Comparison of Three Types of Autoencoder Neural Networks, *Second Asia International Conference On Modelling & Simulation (AMS)*, 13-15 May 2008 Malaysia, IEEE Computer Society, ISBN: 978-0-7695-3136-6, 213-218.

[56]. Şeker, A. ve Yüksek, A.G., 2017, Stacked Autoencoder Method for Fabric Defect Detection, *Cumhuriyet University Faculty of Science Science Journal*, 38 (2), 342-354.

[57]. Kaynar, O., Aydın, Z. ve Görmez, Y., 2017, Sentiment Analizinde Öznitelik Düşürme Yöntemlerinin Oto Kodlayıcılı Derin Öğrenme Makinaları ile Karşılaştırılması, *Bilişim Teknolojileri Dergisi*, 10 (3), 319-326.

[58]. Kao, A. ve Poteet, S.R., 2007, *Natural Language Processing and Text Mining*, Springer-Verlag, London, ISBN: 978-1-84628-754-1.

[59]. Şeker, Ş.E., 2015, Metin Madenciliği (Text Mining), *YBS Ansiklopedi*, 2 (3), 30-32.

[60]. Oğuz, B., Bilge U. ve Saka, O., 2008, Tıpta metin madenciliği, *4. Ulusal Tıp Bilişimi Kongresi*, 15-18 Kasım 2008 Antalya, 108-112.

[61]. Ergün, K., 2012, *Metin Madenciliği Yöntemleri ile Ürün Yorumlarının Otomatik Değerlendirilmesi*, Doktora Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü.

[62]. Kılınç, D., 2018, *Metin İşleme 1-Eski Tarz Yöntemler (Bag of Words ve TFxIDF),* https://medium.com/deep-learning-turkiye/metin-i%CC%87%C5%9Fleme-1-eski-tarz-y%C3%B6ntemler-bag-of-words-ve-tfxidf-76d5a0cf1b29, [Ziyaret Tarihi: 16 Mart 2019].

[63]. Toprak, K., 2018, *Metin Madenciliği Yöntemleri Kullanarak İllere Göre Haber Analizi*, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü.

[64]. Tunalı, V. ve Bilgin, T.T., 2012, Türkçe Metinlerin Kümelenmesinde Farklı Kök Bulma Yöntemlerinin Etkisinin Araştırılması, *ELECO '2012 Elektrik-Elektronik ve Bilgisayar Mühendisliği Sempozyumu,* 29 Kasım-01 Aralık 2012 Bursa, 598-602.

[65]. Demirtaş, M.A., 2018, *Derin Öğrenme Yöntemleri ile Duygu Analizi ve Aktivasyon Fonksiyonlarının Karşılaştırılması*, Yüksek Lisans Tezi, Atatürk Üniversitesi, Fen Bilimleri Enstitüsü.

[66]. Gaikwad, S.V., Chaugule, A. ve Patil, P., 2014, Text Mining Methods and Techniques, *International Journal of Computer Applications*, 85 (17), 42-45.

[67]. Sarawagi, S., 2008, Information Extraction, *Foundations and Trends in Databases,* 1 (3), 261-377.

[68] Dang, S. ve Ahmad, P.H., 2014, Text Mining: Techniques and its Application, *International Journal of Engineering & Technology Innovations,* 1 (4), 22-25.

[69]. Şeker, Ş.E., 2013, *Sınıflandırma (Classification)*, http://bilgisayarkavramlari.sadievrenseker.com/2013/03/31/siniflandirma-classification/, [Ziyaret Tarihi: 20 Mart 2019].

[70]. Berry, M.W. ve Kogan, J., 2010, *Text Mining: Applications and Theory*, John Wiley & Sons Ltd, USA, ISBN: 978-0-470-74982-1.

[71]. Ergün, M., 2017, Using The Techniques of Data Mining and Text Mining in Educational Research, *Elektronik Eğitim Bilimleri Dergisi*, 6 (12), 180-189.

[72]. Talib, R., Hanif, M.K., Ayesha, S. ve Fatima, F., 2016, Text Mining: Techniques, Applications and Issues, *International Journal of Advanced Computer Science and Applications*, 7 (11), 414-418.

[73]. Pasin, E., 2018, *Investıgatıon of Text Mining Methods On Turkish Text,* Thesis (M.Sc.), Dokuz Eylül University.

[74]. Brownlee, J., 2017, *What Is Natural Language Processing*, https://machinelearningmastery.com/natural-language-processing/, [Ziyaret Tarihi: 22 Mart 2019].

[75]. Yıldız, B. ve Ağdeniz, Ş., 2018, Muhasebede Analiz Yöntemi Olarak Metin Madenciliği, *Muhasebe Bilim Dünyası Dergisi,* 20 (2), 286-315.

[76]. Şeker, Ş.E., 2015, Doğal Dil İşleme (Natural Language Processing), *YBS Ansiklopedi,* 2 (4), 14-22.

[77]. Ahmed, W. ve Babu, A.P., 2017, Arabic Question Answering System Based on Data Mining, *International Journal of Scientific & Technology Research*, 6 (2), 237-239.

[78]. Goyal, A. ve Mehta, R., 2012, Performance Comparison of Naïve Bayes and J 48 Classification Algorithms, *International Journal of Applied Engineering Research*, 7 (11).

[79]. Sokolova, M. ve Lapalme, G., 2009, A Systematic Analysis of Performance Measures For Classification Tasks, *Information Processing and Management*, 45, 427-437.

[80]. Marmanis, H. ve Babenko, D.B., 2009, *Algorithms of The Intelligent Web*, Manning Publications, Greenwich, ISBN 978-1-933988-66-5.

[81]. Witten, I.H. ve Frank, E., 2005, *Data Mining: Practical Machine Learning Tools and Techniques (Second Edition)*, Morgan Kaufmann Publishers, San Francisco, ISBN: 0-12-088407-0.

[82]. Chinchor, N., 1992, MUC-4 evaluation metrics, *Proceedings of the Fourth Message Understanding Conference*, 16-18 June 1992 Virginia, ISBN:1-55860-273-9, 22-29.

[83]. Fulk, G.D. ve Sazonov, E., 2011, Using Sensors to Measure Activity in People with Stroke, *Topics in Stroke Rehabilitation*, 18 (6), 746-757,

[84]. Caruana, R. ve Niculescu-Mizil, A., 2004, Data mining in metric space: An empirical analysis of suppervised learning performance criteria, *KDD-2004: Proceedings of the tenth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 22-25 August 2004 Seattle, Washington, ACM Press, ISBN: 1-58113-888-1, 69-78.

[85]. Kim, Y., 2014, Convolutional Neural Networks for Sentence Classification, *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 25-29 October 2014 Doha, Qatar, 1746-1751.

[86]. Lai, S., Xu, L., Liu, K. ve Zhao, J., 2015, Recurrent Convolutional Neural Networks for Text Classification, *Proceedings of the Twenty-Ninth AAAI Conference on Artificial Intelligence*, 25-30 January 2015 Austin, Texas, AAAI Press, ISBN:0-262-51129-0, 2267-2273.

[87]. Zhang, X., Zhao, J. ve Lecun, Y., 2015, Character-Level Convolutional Networks for Text Classification, *Advances in Neural Information Processing Systems Proceedings of the First 12 Conferences*, 7-12 December 2015 Montreal, Canada, MIT Press, 649-657.

[88]. Lee, J.Y. ve Dernoncourt, F., 2016, Sequential Short-Text Classification With Recurrent and Convolutional Neural Networks, *Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies,* 12-17 June 2016 San Diego, California, 515-520.

[89]. Chen, Q., Du, J., Peng, Y., Xiang, Y., Tao, C. ve Lu, Z., 2018, ML-Net: Multi-Label Classification of Biomedical Texts With Deep Neural Networks, *Journal of the American Medical Informatics Association*, 1-7.

[90]. Zhang, M.L. ve Zhou, Z.H., 2006, Multi-Label Neural Networks with Applications to Functional Genomics and Text Categorization, *IEEE Transactions on Knowledge and Data Engineering*, 18 (10), 1338-1351.

[91]. Johnson, R. ve Zhang, T., 2015, Semi-supervised Convolutional Neural Networks for Text Categorization via Region Embedding. *NIPS'15 Proceedings of the 28th International Conference on Neural Information Processing Systems*, 7-12 December 2015 Montreal Canada, MIT Press, 919-927.

[92]. Gonçalves S., Cortez P. ve Moro S., 2018, A Deep Learning Approach for Sentence Classification of Scientific Abstracts, *27th International Conference on Artificial Neural Networks*, 4-7 October 2018 Rhodes, Greece, 479-488.

[93]. Nam J., Kim J., Loza Mencía E., Gurevych I. ve Fürnkranz J., 2014, Large-Scale Multi-label Text Classification-Revisiting Neural Networks, *ECMLPKDD'14 Proceedings of the 2014th European Conference on Machine Learning and Knowledge Discovery in Databases*, 15-19 September 2014 France, Springer-Verlag, ISBN: 978-3-662-44850-2, 437-452.

[94]. Tang D., Qin B. ve Liu T., 2015, Document modeling with gated recurrent neural network for sentiment classification, *Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing*, 17-21 September 2015 Lisbon, Portugal, 1422-1432.

[95]. Kato R. ve Goto H., 2016, Categorization of Web News Documents Using Word2vec and Deep Learning, *Proceedings of the 2016 International Conference on Industrial Engineering and Operations Management*, 8-10 March 2016 Kuala Lumpur, Malaysia, 476-481.

[96]. Kaynar, O., Görmez, Y. ve Işık, Y.E., 2016, Oto Kodlayıcı Tabanlı Derin Öğrenme Makinaları ile Spam Tespiti, *3rd International Management Information Systems Conference*, 6-8 October 2016 İzmir, Türkiye, Gülermat Matbaacılık, ISBN: 978-605-6004-6-6, 44-54.

[97]. Koksal, A. ve Esatoğlu, A. E., 2005, Ankara İlindeki Üniversite ve Özel Hastanelerde Kullanılan Elektronik Hastane Bilgi Sisteminin Analizi, *Ankara Üniversitesi Dikimevi Sağlık Hizmetleri Meslek Yüksekokulu Dergisi*, 7 (1), 53-65.

[98]. Gülcü, A. ve Kuş, Z., N., 2019, Konvolüsyonel Sinir Ağlarında Hiper-Parametre Optimizasyonu Yöntemlerinin İncelenmesi, *Gazi Üniversitesi Fen Bilimleri Dergisi*, 7 (2), 503-522.

[99]. Yıldırım, Ö., 2018, A Novel Wavelet Sequences Based on Deep Bidirectional LSTM Network Model for ECG Signal Classification, *Computers in Biology and Medicine*, 96, 189-202.

[100]. Eldesouki, M., Samih, Y., Abdelali, A., Attia, M., Mubarak, H., Darwish, K. ve Kallmeyer, L., 2017, Arabic Multi-Dialect Segmentation: bi-LSTM-CRF vs. SVM, *ArXiv*, abs / 1708.05891.

[101]. Güneş, A., 2018, *Türkçe'de Varlık İsmi Tanıma*, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	Esra KARASU
Doğum Yeri	Giresun
Doğum Tarihi	05.08.1994
Uyruğu	☑ T.C. ❒ Diğer:
Telefon	-
E-Posta Adresi	esrakarasu28@gmail.com

Eğitim Bilgileri	
Lisans	
Üniversite	Kocaeli Üniveritesi
Fakülte	Mühendislik Fakültesi
Bölümü	Endüstri Mühendisliği
Mezuniyet Yılı	2016

Yüksek Lisans	
Üniversite	İstanbul Üniversitesi-Cerrahpaşa
Enstitü Adı	Lisansüstü Eğitim Enstitüsü
Anabilim Dalı	Endüstri Mühendisliği Anabilim Dalı
Programı	Endüstri Mühendisliği Programı