

**ÇUKUROVA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

DOKTORA TEZİ

Serkan NAS

**ACİL SERVİSLERDE YAPAY SİNİR AĞLARI İLE
TAHMİNLEME VE KAYNAK PLANLAMASI**

ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

ADANA, 2020

**ÇUKUROVA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**ACİL SERVİSLERDE YAPAY SİNİR AĞLARI İLE TAHMİNLEME
VE KAYNAK PLANLAMASI**

Serkan NAS

DOKTORA TEZİ

ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

Bu Tez 24/02/2020 Tarihinde Aşağıdaki Jüri Üyeleri Tarafından
Oybirliği/Oyçokluğu ile Kabul Edilmiştir.

.....
Dr.Öğr.Üyesi Melik KOYUNCU
ÜYE

.....
Prof.Dr. Ali KOKANGÜL
ÜYE

.....
Prof.Dr.Ali AydınSELÇUK
ÜYE

.....
Doç. Dr. Alper ŞEN
ÜYE

.....
Doç. Dr. Gamze VURAL
ÜYE

Bu Tez Enstitümüz Endüstri Mühendisliği Anabilim Dalında hazırlanmıştır.

Kod No:

Prof. Dr. Mustafa GÖK
Enstitü Müdürü

Bu Çalışma Ç. Ü. Araştırma Projeleri Birimi Tarafından Desteklenmiştir.

Proje No: FDK-2018-11379

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge ve fotoğrafların kaynak gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

ÖZ

DOKTORA TEZİ

ACİL SERVİSLERDE YAPAY SİNİR AĞLARI İLE TAHMİNLEME VE KAYNAK PLANLAMASI

Serkan NAS

**ÇUKUROVA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI**

Danışman : Dr. Öğr. Üyesi Melik KOYUNCU
Yıl: 2020, Sayfa: 105
Jüri : Dr. Öğr. Üyesi Melik KOYUNCU
: Prof. Dr. Ali KOKANGÜL
: Prof. Dr. Ali Aydın SELÇUK
: Doç. Dr. Alper ŞEN
: Doç. Dr. Gamze VURAL

Acil ve ölümcül hastaların, hastanede ilk tedavi gördükleri birim olan acil servis (AS) biriminin çok etkin olması gerekir. AS biriminin etkin olabilmesi için de sahip olduğu kaynakların çok verimli kullanılması gerekir. Genellikle, sağlık sistemlerinde kaynak optimizasyonu yapabilmek için simülasyon modellerinden faydalanılır. AS’de yatak sayısının tespit edilmesi çok önemlidir. Çünkü bir çok kaynak yatak sayısına göre planlanır. Bu çalışmada ideal yatak sayısını bulmak amacıyla bir simülasyon modeli geliştirilmiştir. Simülasyon modelinin tasarlanması için gerçek sistemle ilgili bilgilere gereksinim vardır ve bu bilgilerden en önemli girdi parametresi hasta geliş sıklıklarının tahminidir. 10 farklı makine öğrenme algoritması kullanılarak hasta geliş sıklığı tahmin edilmeye çalışılmış, makine öğrenme algoritmalarının girdi olarak kullanacağı ideal öznitelik kümesi de kapsamlı öznitelik seçim yöntemi ile belirlenmiş ve en önemli öznitelik verisi ortalama geliş oranı olarak belirlenmiştir. Uzun Kısa Vadeli Hafıza (LSTM) modeli tahminde mutlak ortalama hata yüzde oranı %46,7 ile en başarılı algoritma olmuş ve simülasyon metodu yardımıyla acil serviste hasta kalış süresi %7 azalmıştır.

Anahtar Kelimeler: Acil Servis (AS), Makine Öğrenme Algoritmaları (MKÖ), Uzun Kısa Vadeli Hafıza (LSTM), Simülasyon

ABSTRACT

PhD THESIS

DEMAND AND RESOURCE PLANNING FOR EMERGENCY SERVICES USING ARTIFICIAL NEURAL NETWORKS

Serkan NAS

ÇUKUROVA UNIVERSITY
INSTITUTE OF NATURAL AND APPLIED SCIENCES
DEPARTMENT OF INDUSTRIAL ENGINEERING

Supervisor : Asst. Prof. Dr. Melik KOYUNCU
Year: 2020, Pages:105
Jury : Asst. Prof. Dr. Melik KOYUNCU
: Prof. Dr. Ali KOKANGÜL
: Prof. Dr. Ali Aydın SELÇUK
: Assoc. Prof. Dr. Alper ŞEN
: Assoc. Prof. Dr. Gamze VURAL

Emergency Department (ED) must be managed effectively since it is the first point of care in hospitals for urgent and critically ill patients. ED can be effective, only by using resources efficiently. Generally, simulation model is used in healthcare systems to optimize resources. In ED, the optimum number of bed resource is crucial, since most of the resources in ED can be planned according to the number of bed resource. This study has developed a simulation model to determine the optimum number of beds. This simulation model needs some inputs and the most important input for this model is patient's arrival rate. 10 different machine learning algorithms are utilized to predict the patient's arrival rate. These machine learning algorithms need optimum feature subsets and this optimum subset has been determined by using exhaustive feature selection method. The most significant feature is identified as mean arrival rate. The long short-term memory (LSTM) model has the best accuracy with a MAPE value of 46,7%, and by the help of the simulation method, the length of stay (LOS) has been minimized by 7% and the number of beds at the ED has been optimized.

Key Words: Emergency Department (ED), Machine Learning Algorithms (ML), Long Short-Term Memory (LSTM), Simulation

GENİŞLETİLMİŞ ÖZET

Sağlık, bir toplumun sahip olduğu en değerli varlıklardan biridir. Sağlıklı bir toplumun üretkenliği de yüksek olacağından, sağlıklı bir toplum aynı zamanda refah toplumu olabilmektedir. Acil servisler (AS), ölümcül hastaların ve kalıcı yaralanmaların ilk tedavi noktası olmasından dolayı, tüm sağlık sistemlerinde çok önemli bir rol oynamaktadır. Acil servislerde sunulan sağlık hizmetlerinin kalitesini yükseltmek, toplum sağlık kalitesini yükseltmede önemli rol oynamaktadır. Bu sebeple, sağlık hizmetlerinin kalitesini artırmak için, acil servislerin çok etkin olması gerekmektedir. AS'lerin etkinliğinin sağlanabilmesi için bütçe kısıtları içinde sahip oldukları kaynakların en iyi şekilde kullanılması gerekmektedir. Özellikle, ülkemiz gibi gelişmekte olan ülkelerde sağlık harcamalarına yeteri kadar bütçe ayrılamaması, kaynakların verimli kullanılmasını daha önemli kılmaktadır. İdeal kaynakların belirlenmesinde, yöneylem tekniklerin en iyi yöntemlerinden biri olan simülasyon modelleme yöntemi ile kaynakların planlanması amaçlanmış ve simülasyon modeli hasta geliş sıklığı, hasta bekleme süresi gibi tasarlanacak modele ait verilerin girdi olarak kullanmasına ihtiyaç duymaktadır. Hasta bekleme süresi literatürde kabul gördüğü gibi, acil servislerin performansı açısından en önemli göstergelerden biridir. Acil serviste hastaya ne kadar hızlı müdahale edilirse kalıcı yaralanmalar ve ölümler o oranda azalır. Hasta bekleme süresinin acil servisteki yatak yeterliliği ile önemli ölçüde ilişkisi olmasından dolayı, bu çalışmada hasta bekleme süresini minimize etmek amacıyla, ideal yatak sayısını bulmamıza yardımcı olacak bir simülasyon modeli geliştirilmiştir. Simülasyona girdi olacak verileri hazırlamak amacıyla, hastane verileri incelenmiş, hasta bekleme süresi, hastaların acil servisteki rotaları , tedavi süreleri gibi acil sistemi modellememizi sağlayacak veriler belirlenmiştir. Hasta geliş sıklığının tahmin edilebilmesi için hasta geliş sıklığı ile ilgili öznitelikler belirlenmiştir. Literatür taramaları, en çok kullanılan özniteliklerin zamansal değerler ve hava durumu olduğunu göstermiştir. Bu özniteliklere, bu çalışmada

ortalama hasta geliş sıklığı eklenmiştir. Öznitelik seçim kurallarından diğer geleneksel kurallardan farklı olarak, kapsamlı öznitelik seçim kuralı kullanılmıştır. Çünkü diğer seçim kurallarının hata yapma olanağı var iken, kapsamlı öznitelik seçimi en ideal öznitelik kümesini bulabilmektedir. Bu çalışmada, ideal öznitelik kümesinde tahmin başarısına en önemli katkı yapan öznitelğin ortalama hasta geliş oranı olduğu tespit edilmiştir. Ortalama hasta geliş oranı özniteliği de literatürde kullanılmamış bir özniteliktir. Bu çalışmada, 1 yıllık veri ile günlük ve saatlik hasta geliş sıklığı tahmini, 5 yıllık veri ile de (43.824 çalışma saati) saatlik hasta geliş sıklığı tahmini yapılmıştır. 5 yıllık veri ile yapılan çalışmada, daha çok veri yapısı ile makine öğrenme algoritmalarının başarısın değişimi gözlemlenmek istenmiştir. Literatürde tanımlandığı gibi özellikle yapay sinir ağları ile yapılan çalışmada veri büyüklüğü sonuçlara olumlu yansımaktadır. Bu çalışmada da bu veri yapısının büyüklüğü sonuçlara olumlu yansımıştır. Aynı ideal öznitelik kümesi ile 10 farklı makine öğrenme algoritması çalıştırılmış ve fazla sayıda makine öğrenme algoritması kullanılarak, tahmin keskinliği yüksek olan algoritmaya ulaşılması hedeflenmiştir. Çünkü, makine öğrenme algoritmalarının başarısı, modeldeki parametreler kadar kullanılan verinin yapısına da bağlı olmaktadır. Bu çalışmada da farklı verilerde, farklı makine öğrenme algoritmaları başarı sağlamıştır. Çalıştırılan makine öğrenme algoritmaları, karar ağacı, rasgele orman, destek vektör mekaniği algoritması, en yakın k komşuluğu, gradyan artırımı, stokastik gradyan artırımı, adaboost, çoklu katmanlı algılayıcı, lojistik regresyon ve tekrarlayan yapay sinir ağlarıdır. 10 katlamalı çapraz doğrulama yöntemi ve performans ölçütü olarak ortalama mutlak yüzde hatası (OMYH) temel alınarak yapılan makine öğrenme algoritmalarının çalıştırılması sonucu en iyi performansı %47 OMYH oranı ile tekrarlayan sinir ağlarının bir türü olan uzun vadeli kısa hafıza (LSTM) modeli göstermiştir. Simülasyon modeli kullanılarak ideal hasta yatak sayısı tespit edilmiştir. İdeal yatak sayısı ile geliştirilen simülasyon modeli çalıştırıldığında acil serviste hasta kalış süresi %7 oranında azaldığı tespit edilmiş ve AS' deki sağlık hizmet kalitesinin yükseltilmesine önemli bir katkı sağlanmıştır.

TEŞEKKÜR

Doktora öğreniminin ve çalışmamın her aşamasında benden yardımlarını esirgemeyen, yapıcı ve yönlendirici fikirleri ile bana daima yol gösteren çok değerli danışman hocam Dr. Öğr. Üyesi Melik KOYUNCU' ya sonsuz teşekkür ederim.

Doktora Tez İzleme Komitesi üyeleri Prof. Dr. Ali KOKANGÜL' e ve Doç. Dr. Gamze VURAL'a çalışmamın tüm aşamalarında yönlendirici ve olumlu katkılarından dolayı sonsuz teşekkür ederim.

Doktora çalışmamdaki kıymetli katkılarından dolayı değerli hocalarım Prof. Dr. Ali Aydın SELÇUK ve Doç. Dr. Alper ŞEN'e sonsuz teşekkür ederim.

Doktora çalışmamdaki değerli katkılarından dolayı Prof. Dr. Rızvan Erol'a çok teşekkür ederim.

Doktora çalışmalarım esnasında tüm bölüm olanaklarından yararlanmamı sağlayan Ç.Ü. Mühendislik Fakültesi Endüstri Mühendisliği Bölüm Başkanlığı'na, maddi destek veren Ç.Ü. Bilimsel Araştırma Projeleri Birimi'ne (Proje No: FDK-2018-11379) teşekkür ederim.

Son olarak, çalışmam boyunca manevi destekleriyle beni hiçbir zaman yalnız bırakmayan aileme de sonsuz teşekkürler ederim.

İÇİNDEKİLER

SAYFA

ÖZ	I
ABSTRACT.....	II
GENİŞLETİLMİŞ ÖZET	III
TEŞEKKÜR.....	V
İÇİNDEKİLER	VI
ÇİZELGELER DİZİNİ	X
ŞEKİLLER DİZİNİ	XII
SİMGELER VE KISALTMALAR.....	XIV
1. GİRİŞ	1
1.1. Acil Servisler.....	3
1.2. Simülasyon	5
1.3. Yapay Sinir Ağları	7
1.4. Makine Öğrenmesi	10
1.5. Öznitelik Seçimi (Feature selection).....	13
1.6. Problemin Tanımı	15
1.7. Çalışmanın Amacı.....	16
1.8. Çalışmanın Kapsamı	17
1.9. Çalışmanın Özgün Katkısı	17
1.10. Çalışmanın Adımları ve Organizasyonu	18
1.10.1. Çalışmanın Adımları	18
1.10.2. Çalışmanın Organizasyonu	19
2. ÖNCEKİ ÇALIŞMALAR	21
2.1. Tahmin Etme Yöntemleri ile İlgili Çalışmalar	21
2.1.1. Hasta Geliş Sıklığı ve Hasta Kalış Süresi ile İlgili Çalışmalar.....	21

2.1.2. Makine Öğrenme Algoritmalarında Öznitelik Seçimi ile İlgili Çalışmalar	30
2.2. Acil Servislerde Kalabalık Sorununu İyileştirmek Amacıyla Yapılan Simülasyon ile İlgili Çalışmalar	33
3. MATERYAL VE METOT	41
3.1. Materyal	41
3.2. Metot	44
3.2.1. Yapay Zeka	46
3.2.1.1. Uzman Sistemler	48
3.2.1.2. Bulanık Mantık	48
3.2.1.3. Genetik Algoritma	49
3.2.1.4. Karınca Algoritması	50
3.2.1.5. Tabu Algoritması	50
3.2.1.6. Yumuşak Programlama	50
3.2.1.7. Yapay Sinir Ağları	51
3.2.1.7.(1). Tekrarlayan Sinir Ağları	56
3.2.1.7.(1).a. Uzun Kısa Dönem Hafızası	58
3.2.1.8. Makine Öğrenmesi	59
3.2.1.8.(1). Karar Ağacı	60
3.2.1.8.(2). Gradyan Artırımı	61
3.2.1.8.(3). Lojistik Regresyon	62
3.2.1.8.(4). Rasgele Orman	62
3.2.1.8.(5). K-en Yakın Komşu	63
3.2.1.8.(6). Destek Vektör Makinesi	64
3.2.1.8.(7). Çok Katmanlı Algılayıcılar	64
3.2.1.8.(8). Stokastik Gradyan Regresyon	65
3.2.1.8.(9). Adaboost,	65
3.2.2. Öznitelik Seçimi	65

3.2.3. Simülasyon	67
3.3. Model Geliştirme	70
3.3.1. Yapay Sinir Ağları Modelinin Geliştirilmesi.....	71
3.3.2. Makine Öğrenme Algoritmasının Geliştirilmesi	74
3.3.3. Simülasyon Modelinin Geliştirilmesi	74
4. BULGULAR VE ARAŞTIRMALAR.....	79
4.1. Bulgular	80
4.1.1. Öznitelik Kümesinin Bulunması	80
4.1.2. En İyi Makine Öğrenme Algoritmasının Bulunması.....	82
4.1.3. Simülasyon Modeli ile İlgili Bulgular.....	87
4.1.4. Simülasyon Modeli ile Kaynak Planlaması.....	90
5. SONUÇLAR VE ÖNERİLER	93
5.1. Sonuçlar	93
5.2. Öneriler.....	95
KAYNAKLAR	97
ÖZGEÇMİŞ	105



ÇİZELGELER DİZİNİ

SAYFA

Çizelge 4.1. 1 yıllık veri ile 10 farklı makine algoritmasının 10 katlamalı çapraz doğrulama yöntemiyle elde edilen hasta geliş sıklığı günlük tahmin verilerinin OMYH istatistik sonuçları	83
Çizelge 4.2. 1 yıllık veri ile 10 farklı makine algoritmasının 10 katlamalı çapraz doğrulama yöntemiyle elde edilen hasta geliş sıklığı saatlik tahmin verilerinin OMYH istatistik sonuçları	84
Çizelge 4.3. 5 yıllık veri ile 10 farklı makine algoritmasının 10 katlamalı çapraz doğrulama yöntemiyle elde edilen hasta geliş sıklığı saatlik tahmin verilerinin OMYH istatistik sonuçları	84
Çizelge 4.4. Acil Serviste Tedavi Süreleri	89



ŞEKİLLER DİZİNİ

SAYFA

Şekil 1.1. Refah Düzeyi İle Sağlık Düzeyinin İlişkisi	2
Şekil 1.2. OECD Ülkelerinin Sağlık Harcamalarının GSYİH'daki Yüzde Payı	2
Şekil 1.3. Yapay Sinir Ağlarının Basit Bir Modeli	7
Şekil 1.4. LSTM Modeli	10
Şekil 3.1. Arena Yazılımında Ara Yüz	44
Şekil 3.2. Geri Yayılım Algoritmasının Çalışma Şekli.....	55
Şekil 3.3. Tekrarlayan Sinir Ağı	56
Şekil 3.4. İleri Beslemede Tekrarlayan Nöron Açılımı.....	57
Şekil 3.5. Sistem İnceleme Çalışma Metodu (Law,2007).....	68
Şekil 3.6. Sızıntılı ReLU Aktivasyon Fonksiyonu.....	72
Şekil 3.7. Tekrarlayan Sinir Ağlarının Modeli	74
Şekil 3.8. Kesikli Olay Simülasyon Modelinin Tipik Bir Akış Şeması.....	77
Şekil 4.1. Özniteliklerin Hedefle ilgili Korelasyon Sonuçları	81
Şekil 4.2. LSTM, Poisson, Ortalama Geliş Oranı ve Diğer 9 MKÖ Algoritmasının Tahmin OMYH Değerlerinin Karşılaştırılması.....	86
Şekil 4.3. LSTM ile Yapılan Çalışmada Gerçek Değer ile Tahmin Değerinin Karşılaştırılması	86
Şekil 4.4. Acil Servis Hasta Akış Şeması	88
Şekil 4.5. Welch Metoduyla Kararlı Hale Gelme Süresi Grafiği.....	90
Şekil 4.6. Yatak Sayısı ile Hasta Bekleme Süresi Arasındaki İlişki	91
Şekil 4.7. Yatak Sayısı ile Yatak Sırası Arasındaki İlişki.....	92



SİMGELER VE KISALTMALAR



AB	: AdaBoost
AS	: Acil servis
ÇKA	: Çok katmanlı algılayıcı
DR	: Doğrusal regresyon
DVM	: Destek vektör mekaniği
HBS	: Hasta bekleme süresi
HKS	: Hasta kalış süresi
GA	: Gradyan artırım
KA	: Karar ağacı
K-EYK	: En yakın k komşuluğu
LR	: Lojistik regresyon
LSTM	: Uzun vadeli kısa hafıza
MKÖ	: Makine öğrenme algoritması
OMYH	: Ortalama mutlak yüzde hatası
RNN	: Tekrarlayan sinir ağları
RO	: Rasgele orman
SGA	: Stokastik gradyan azalımı
YSA	: Yapay sinir ağları
YZ	: Yapay zeka



1. GİRİŞ

Bir ülkenin refah toplumu olabilmesin için yetişmiş insan gücünün yüksek olması gerekmektedir. Yetişmiş insan gücü, toplumun her alanda üretken olabilmesi için gerekli bilgi, kabiliyet, deneyim, iş ahlakının ve kültürün ulaştığı düzeyi; diğer yandan bedensel ve ruhsal sağlamlığını belirten bir kavram olarak ifade edilebilir (Taban, 2006). Bu sebeple sağlıklı insan gücü, bir toplumun sahip olduğu en önemli varlıkların başında gelir. Toplum içinde sağlıklı insan gücü üretimi, yaratıcılığı ve ilerlemeyi sağlar. Hastalık ve ölüm ise toplum için ciddi bir kayıptır. Bu sebeple, tüm ülkeler insan gücüne yani sağlık hizmetlerine yatırım yapar ve bunu ekonomik kazanç olarak görür. Çünkü, sağlık hizmetleri, toplumların yaşam kalitesini yükselterek, hastalık ve ölümleri en aza indirmeyi amaçlar. OECD ülkeleri için yapılan sağlık harcamalarının gayri safi yurt içi hasıla (GSYİH) içindeki payı %1 artarsa, ekonomik büyümenin %0,903 oranında arttığı saptanmıştır. Toplumun sağlık seviyesi ile ekonomik refah seviyesi arasındaki ilişki Şekil 1.1’ de verilmiştir(Kamacı ve ark. 2017).

Gelişmiş ülkelerde sağlığa verilen önem çok fazla olduğu için, konu ile ilgili yapılan harcamalar da oldukça yüksektir. Gelişmiş ülkeler birbirlerinden farklı sağlık sistemleri ile gayri safi yurt içi hasıllarının önemli bir kısmını sağlık harcamalarına ve yatırımlarına ayırmaktadırlar. Gelişmiş ülkelerin GSYİH’lerinin kişi başına yüksek olması, sağlık için ayrılan kısmın da yüksek olması kişi başına sağlık harcamalarının oldukça yüksek seviyelerde olmasına neden olmaktadır. Gelişmiş ülkelerde sağlık harcamaları, az gelişmiş ülkelere göre 5-6 kat fazla olmaktadır. Ülkemiz sağlık harcamaları konusunda OECD ülkeleri arasında en sonda yer almaktadır. Ülkelerin gayri safi yurt içi hasıllarının yüzde kaçını sağlığa ayırdıkları OECD.org sitesinden veriler alınarak Şekil 1.2.’de sunulan grafik düzenlenmiştir.



Şekil 1.2. OECD Ülkelerinin Sağlık Harcamalarının GSYİH'daki Yüzde Payı

Bu çalışmada sağlık hizmeti verilen kurumlar arasında en önemli birim olan hastanelerde gözlemler yapıldı ve yönetimleri ile görüşüldü. Yapılan

gözlemler de sağlık harcamaları ile sağlık hizmetleri arasında birebir korelasyon olmadığı tespit edildi. Bu da kaynak kullanımının optimizasyonunun sağlık sistemlerinin etkinliğinde çok önemli olduğunu ve sınırlı kaynaklara sahip gelişmekte olan ülkeler için bunun çok daha önemli bir rol oynadığı belirlenmiştir. Ülkemiz gibi sağlık harcamalarına az kaynak ayıran ülkelerde de bu konu çok fazla önem kazanmaktadır. Ülkelerde sağlık seviyesini yükseltmek için hastanelerden başlanmalıdır. Hastanelerde ise en önemli birim acil servislerdir ve acil servislerde herhangi bir hata ölümcül olabilir (Yousefi ve ark, 2018). Bu birimlerde zamanında yapılmayan bir sağlık hizmeti kalıcı hasarlara da sebep olabilir. Bu sebeple, bu çalışmada sağlık seviyesinin yükseltilmesine en çok etki yapabileceğimiz birim olan acil servislerdeki kaynak optimizasyonu problemi ele alınmıştır.

1.1. Acil Servisler

Acil servisler, ani ve beklenmedik bir anda kişinin hayatını tehdit eden bir hastalık ya da yaralanma durumunda, hastanın ilk değerlendirilmesinin, tedavisinin yapıldığı, ileri bakım ve takibinin ilgili hekime bildirildiği alanlardır. Bu birimlerde sakatlık ve ölüm gibi risklerin kontrolü için kesintisiz olarak hizmet verilmektedir. Acil servislerde, hasta başvurusu sınırlandırılmadan 7 gün 24 saat kesintisiz olarak alınmaktadır (Yousefi ve ark, 2018).

Ülkemizde uygulanan sağlık politikalarından dolayı acil servise gelen hasta sayısı ve profili değişiklikler göstermektedir. Acil servise başvuran hastalar incelendiğinde, acil tedavi dışındaki bölümlerde tedavi olması gereken hasta sayısının da oldukça fazla olduğu belirlenmiştir. Toplumda yaş ortalaması yükseldiğinden 65 yaş üstü hastaların özellikle bu birimlerde tedaviye başvurduğu görülmektedir. Biyoterörizm, salgın hastalıklar ve doğal afetler gibi... Özel durumlar da acil servislerin önemini arttırmaktadır. Tüm bu açılardan bakıldığında, acil servislerin etkin çalışmasının toplumun sağlık seviyesine ciddi katkılarda bulunduğu söylenebilir.

Bu servislerde her türlü hasta muayene edilmekte, bu durum yüksek maliyet ve bütçe sıkıntıları oluşturmaktadır. Bunun sonucunda, acil servislerin hastane bütçesinden fazla pay alması gerekmektedir. Özellikle gelişmekte olan ülkelerde kaynakların sınırlı olması acil servislerin etkin ve verimli çalışmasında kaynak optimizasyonu konusunu daha fazla önem kazandırmaktadır. Optimizasyon yaparken, acil servisin konumu (anayola yakın olması vs.), dış tasarım faktörleri (ambulans giriş parkı, ayakta hasta girişi vs. gibi...), yan komşuları (x-ray servisi, ameliyathane vs.) yatak sayısı, yatak alanı, yatak tipi, oda tipleri, triaj alanı, malzemeler, ekipman vb. ve sağlık personeli gibi tüm faktörlerin yönetimi gerekmektedir.

Kaynak planlamasını optimize etmek için hastanelerin yönetiminde çeşitli metotlardan yararlanılmaktadır. Bu metotlara örnek vermek gerekirse; yöneylem araştırması tekniklerinin en önemlilerinden, matematiksel programlama, kuyruk teorisi ve simülasyon modelleme teknikleri sıralanabilir. Acil servis birimlerinde yüksek seviyede kalabalık ve belirsizlik problemi yaşandığından simülasyon metotları acil servis birimlerinin modellenmesinde ve problemlerinin çözümünde daha fazla kullanılmaktadır. Acil servisler planlanırken, gelen her hastaya en kısa sürede cevap verebilmek, olabildiğince hızla muayene edebilmek ve olabildiğince hızlı taburcu olmasını sağlamak amaçlanmıştır. Acil servislerin en önemli performans göstergesi, hastanın acil serviste kalış süresidir. Acil servislerde hastalar randevu sistemi ile çalışamayacağından, belirsizlik doğal olarak yüksek olmaktadır. Bu belirsizlik de kalabalığa, daha fazla bekleme zamanına yol açmakta, sonuç olarak daha az kaliteli sağlık hizmeti sunulmaktadır. Simülasyon yöntemi, belirsizliğin yüksek olduğu sistemlerde, o sistemi modelleyebilmekte kullanılan etkili yöntemdir. Bu nedenle, simülasyon acil servislerin yönetiminde taktiksel ve stratejik karar verme süreçlerinde önemli bir uygulamadır (Gül ve ark, 2015).

1.2. Simülasyon

Simülasyon modelleme, bilgisayar ve uygun yazılımdan faydalanılarak, gerçek sistemin davranışlarını taklit etmek için kullanılan tüm metot ve uygulamaların bütünüdür. Simülasyon genel bir terim olup, endüstride ve diğer birçok alanda uygulanabilmektedir. Günümüzde, bilgisayar ve yazılımların kullanımının çok gelişmiş olmasından dolayı simülasyon modellemesinin kullanımı çok yaygın hale gelmiştir (Kelton ve ark, 2010).

Sistemlerin modellenmesine ihtiyaç duyulmasının sebebi, birçok fiziksel sistemin oldukça karmaşık olması ve sistem davranışlarını etkileyen birçok parametrenin bulunmasıdır. Sistemleri incelerken en basit yöntem, bu sistemleri kurmak ve birçok kontrollü deney yaparak sistemi incelemektir. Fakat, sistemler genelde lineer olmayan iki değişkenli sistemler olup, değişkenleri aynı anda değiştirmenin toplam etkisi, değişkenlerin tek tek değişiminden çok daha farklı sonuçlar vermektedir. Bu durum bizim çok fazla kombinasyon yapmamızı gerektirebilir; bu da sistemi tasarlamamızı ve bunca deneyi yapmamızı imkansız hale getirebilir. Ayrıca bu deneyleri ve tasarımları yapmak çok tehlikeli veya çok masraflı olabilir. Bu sebeple, çok karmaşık sistemlerin incelenmesi, davranışlarının anlaşılması için tüm sisteme ait bilgilerin ele alınabildiği, dilediğimiz gibi parametrelerde değişiklik yapabileceğimiz bilgisayar simülasyonları ile gerçek sistemleri kurmadan bu sistemler incelenebilir ve sisteme ait iyileştirmeler veya bazı kriterlerdeki optimizasyonlar yapılabilir (Woolfsan ve ark, 1999).

Birçok farklı bilgisayar simülasyon modellemesi bulunmaktadır. Sistem dinamikleri, kesikli olay simülasyonu, etmen tabanlı simülasyon modellerini bunlara örnek verilebilir. Sistem dinamikleri ile kesikli olay simülasyonu farklı durumlar için kullanılırlar ve kesikli olay simülasyonu ile etmen tabanlı simülasyonun karşılaştırılmasında hangisinin daha iyi gerçek problemi resimlediği konusu hala tartışmalıdır (Brailsford, 2014). Acil servisleri kesikli olay simülasyonu ile analiz etmemiz sistemi çok daha iyi anlamamızı ve aynı zamanda süreçleri veya parametreleri değiştirmemizin hasta akışını ve kaynak kullanım

oranlarını nasıl etkilediğini incelememize imkan verir (Komashie, 2005). Bu çalışmada incelenen acil servis gibi karmaşık bir sistemde olaylar kesikli olarak değiştiği için, kesikli olay simülasyonun gerekli olduğu düşünülmüştür. Simülasyon modellerinde farklı senaryolar denenerek, istenilen hedefe ulaşmamıza yardımcı olacak çözüm bulunur. Bu çalışmada değiştirilen senaryolar acil servisteki yatak sayıları olarak belirlenmiştir. Yatak sayıları değiştirilerek, hasta kalış süresindeki değişim de bu modelle incelenmiş ve ideal yatak sayısı belirlenmiştir.


Simülasyonun başarısı gerçek sistem ile modelin birbirine benzerlik oranına bağlıdır. Benzerlik ne kadar artarsa başarı oranı da o kadar yüksek olacaktır. Acil servisin simülasyonla modellemesinde kullanılan verilerin, hasta geliş sürelerinin, hasta kalış sürelerinin ve hasta tedavi sürelerinin olabildiğince gerçekçi olarak tespit edilmesi gerekmektedir. Bu sebeple, hasta geliş sürelerinin tahmini acil servis sisteminin simülasyonla modellemesinde çok önemli bir rol oynamaktadır. Acil servislerin kalabalık olmasının en önemli sebebi yatak kaynağının kullanımının doğru planlanmamasıdır, bu da hasta akışının yönetilmesinin önemini artırmaktadır (Olshaker ve ark, 2006). Gelen her hastaya hizmet verebilmek için insan kaynaklarının tahsisi de yatak talebine göre ayarlanmaktadır (Carvalho ve ark, 2018). Hasta geliş sıklığına bağlı olarak yatak talebinin tahmin edilmesi hastane kaynaklarının etkin bir şekilde kullanılması ve acil serviste hasta bekleyiş sürelerinin azalmasını sağlayacaktır (Lucini ve ark ,2017).

Hasta geliş sıklığını tahmin edebilmek için farklı yaklaşımlar bulunmaktadır. Yapay sinir ağlarının bir alt kümesi olan makine öğrenmesi, hasta geliş sıklığı gibi hedef değişkenlerin tahmin edilmesinde bu yaklaşımların içinden en iyi olanlardandır. Yapay sinir ağları teknolojisi yakın gelecekte acil servislerin her yönünde çok etkili olacaktır (Stewart ve ark, 2018). Doğrusal olsun ya da olmasın bu geleneksel matematik modellerinden farklı olarak yapay sinir ağları çok büyük verileri içeren karmaşık problemleri çözümleyebilmekte; uygulamaya

konulan bu yapay sinir ağı, hastane personeli için kullanımı çok kolay olmakla birlikte çok iyi bir tahmin aracı olarak da kullanılmaktadır (Schiavo,2015).

1.3. Yapay Sinir Ağları

Yapay sinir ağlarının (YSA), üzerinde anlaşılan bir tanımı bulunmamaktadır. Yapay sinir ağlarını, insanın öğrenme, tecrübe etmesi, ve bu öğrendiklerini yeni bilgi geldikçe yorumlanması, tanımlarını bu bilgiler çerçevesinde değiştirmesi ve sürekli olarak bilginin yenilenmesi ve yeni bilgiye göre düşünce çıktısının iyileştirilmesi sürecine benzeyen durumun bilgisayar yardımıyla yapılması olarak tanımlayabiliriz (Sağıroğlu ve ark, 2003). Basit bir YSA modeli Şekil 1.3.'de verildiği gibidir.



Şekil 1.3. Yapay Sinir Ağlarının Basit Bir Modeli

YSA beynimizin yaptığı karmaşık çözümlerlerin bilgisayar tarafından yapılabileceği varsayılarak geliştirilmiştir. İnsan beyni birbirine bağlı nöronların kimyasal bağlılığı ile düşünür, bu da yapay zekanın hesaplama gücüne karşılık gelir. Soruların cevaplarına ulaşmak veya sorunların çözülmesi için kullanılan metodoloji insanın kişisel özelliklerine ve yöntemlerine karşılık gelmektedir. İnsan belleği de tam olarak bilgisayar hafızasına karşılık gelir ve YSA'da da birçok işlemci yapı bulunmaktadır. İnsanlar gibi YSA'nın da farklı öğrenme biçimleri bulunmaktadır ve bu öğrenme yaklaşımlarına göre eğitim sırasında çarpan

ağırlıkları değiştirilir. Ağırlıklarda yapılan ince ayarlar bittiğinde öğrenmenin tamamlandığı kabul edilir. İnsan düşünce sistemine benzer olarak YSA da doğrusal değildir. Bu özellik onların doğadaki her soruna çözüm yaklaşımı getirebilmelerine olanak sağlamaktadır. Yapısının düzgün tasarlanması durumunda YSA, çıktı verileri olmadan da sadece girdi verileri ile de öğrenebilir. YSA'da veri örnekleme sayısı çoğaldıkça öğrenme oranı da artar. Problemlerin çözümünde mevcut veriler ile elde ettiği sonuçlar yetersiz olduğunda bile, sisteme yeni veriler eklendiğinde çok daha doğru sonuçlara ulaşabilir. Biyolojik sistemde veri dağılık halde bulunurken, YSA'da ağırlıklar üzerinde paralel olarak konulmuş olarak korunmakta ve bilgi farklı biçimlere dönüştürülerek kullanılabilir. Nöron bağlantılarında ağırlıkların etkisi vardır ve bu ağırlıklar üzerine gürültü etkisi dağıtıldığı için gerçek veriler ile gürültü arasında denge kurulur. YSA'da yapay nöronlar, aktivasyon fonksiyonu ve ileri veya geri beslemeli yapı bulunur. Ayrıca YSA yapısında denetimli veya denetimsiz, öğrenme kuralları gibi farklılıklar bulunmaktadır (Sağıroğlu ve ark, 2003).


YSA'nın başarısı, aktivasyon fonksiyonu, öğrenme algoritması, yapay nöron yapısı gibi tüm etmenlerin seçimine bağlıdır. Aktivasyon fonksiyonlarına, doğrusal fonksiyon, basamak fonksiyon, kutuplamalı basamak fonksiyon, parçalı doğrusal fonksiyon, sigmoid veya tanjant hiperbolik fonksiyonlar örnek verilebilir. Öğrenme algoritmaları, ilişkilendirme kuralları, sınıflandırma, bağlantım, denetimsiz öğrenme ve denetimli öğrenme şeklindedir. Nöron ve katman sayıları da, YSA'yı hem olumlu hem de olumsuz etkileyebilmektedir (Apaydın, 2013). Aktivasyon fonksiyonu veya öğrenme algoritması seçimi için bazı yol göstericiler bulunsun da, maalesef nöron katman yapısı için deneme yanılma yöntemi dışında en iyiyi bulma yöntemi henüz bulunmamaktadır. YSA'nın yapısı kullanıldığı amaca göre oluşturulur. Genel olarak karmaşık matematiksel modeller için uygun olan YSA'ları, mühendislik uygulamalarında tahmin, sınıflandırma, veri ilişkilendirme, veri yorumlama ve filtreleme konularında kullanılır. Bunun dışında havacılık,

eğlence, finans, tıp, otomotiv ve daha birçok sektörde kullanılmaktadır. Bizim çalışmamızda da tahmin konusunda YSA'dan yararlanılmıştır.

Tahmin konusunda eğer veri bilgisinde sıra bilgisi önemliyse tekrarlayan sinir ağları kullanılır. Tekrarlayan sinir ağları geleneksel YSA'ların biraz daha gelişmiş bir çeşididir denilebilir. Tekrarlayan sinir ağları sağlık sistemlerinde, finans piyasalarında, satış tahminlerinde ve birçok konuda başarılı olmuş, çok kullanılan modellerdir. Diğer YSA modellerinden farklı olarak, verilerin birbirinden bağımsız olmadığını kabul ederek, geçmiş veri ile bugünkü veri arasında ilişki kurar ve bunlara ağırlık vererek, geçmiş verileri de dikkate alarak doğru çıktıya ulaşmaya çalışır. Verilerin sıralaması önemli ise özellikle zamana bağlı olarak çıktı değişimi olduğunda, tekrarlayan sinir ağları kullanılmalıdır. Tekrarlayan sinir ağlarında çıktı sadece o andaki girdiye göre değil, diğer girdilerin çıktılarına bağlı olarak da çıkarılır. Bir nöron katmanından çıkan çıktılar, bir sonraki katman için girdi olarak kullanıldıklarında, tekrarlayan sinir ağları ileri beslemeli ağlardan ayrılmış olur. Bu ağların farkı bir belleğe ihtiyaç duymasıdır. Bir önceki girdi bellekte tutulur, belli bir ağırlık ile çarpılır, sonra mevcut girdi yine kendine özel ağırlığı ile çarpılır ve çıktı elde edilir. Elde edilen çıktıda oluşan hatayı en az indirmek için delta kuralı veya gradyan inişinden faydalanarak, geri yayılım yöntemiyle hata küçültülür. Birbirine bağlı uzun ağlarda gradyan değeri yok olmakta veya aşırı büyümektedir (Sağıroğlu ve ark, 2003). Gradyan değeri ağırlıkların hesaplanmasında rol oynar, bu da bizim doğru sonuca ulaşmamızı imkansız hale getirmektedir. Bu problemin birkaç yöntemle çözülebileceği bilinmektedir.

Bu yöntemlerden biri sadece bu tür problemleri çözmek için bulunan ve kullanılan Uzun Kısa Vadeli Hafıza Ağları (LSTM) metodudur. Tekrarlayan ağlarda tek bir sinir katmanı var iken, LSTM'de 4 parça birbiri ile ilişki içinde çalışır. Bu parçalar hangi değerlerin tutulup hafızada saklanacağına, hangi değerlerin silineceğine ve tutulan değerlerden çıktı elde edileceğine karar verir. Bu çalışmada, geçmiş veri ile bir sonraki veri arasında kurulan bağlantı, tekrarlayan

sinir ağlarını güçlendirmek için (LSTM) kullanılmıştır. Şekil 1.4’de LSTM modelinin örneği bulunmaktadır. Ayrıca, 9 farklı makine öğrenme algoritması da kullanılmıştır. Makine öğrenme algoritmaları tahmin problemlerinin çözümünde oldukça faydalı olmaktadır. Algoritma seçimi bazı bilgilere dayanarak yapılabilir ancak hangi algoritmanın başarılı olacağı farklı unsurlara bağlıdır. Algoritmaların başarısını, tahmin edecek verinin yapısı, bu veri kümesine dahil edilen öznitelikler, özniteliklerin kombinasyonlarıyla oluşturulan öznitelik kümesi, algoritmalar için seçilen parametreleri, tahmin çalışmamızda gerçek sonuç ile tahmini sonuç arasındaki hata payını minimize etme konusunda çok etkili olduğu saptanmıştır.



Şekil 1.4. LSTM Modeli

1.4. Makine Öğrenmesi

Makine öğrenmesi yapay zekanın bir alt kümesi olup, farklı genel algoritmaların toplandığı bir kümedir. Makine öğrenmesi, geçmiş verilerden veya örneklerden yararlanılarak, bir ölçü değerinin bilgisayar yardımı ile iyileştirilmesi ve en iyinin bulunması şeklinde tanımlanmaktadır. Veri genişliğimiz, ayırt edici özelliklerimiz, ne kadar çok ve anlamlı olursa, o kadar çok doğru sonuca varmamız mümkün olabilir. Makine öğrenmeleri denetimli, denetimsiz veya takviyeli

öğrenme gibi türlere ayrılır. Denetimli öğrenmede, modelin hedefi bellidir, etiketli veri içerir, sınıflama ve regresyon için kullanılır. Denetimsiz öğrenme insanın öğrenme şekline daha yakın bir öğrenme şekli olduğu bilinmektedir. Kümeleme ve birliktelik analizi denetimsiz öğrenme ile kullanılmaktadır. Etiketlenmiş veri yoktur ve modelin hedefi belli değildir. Bu analiz yöntemlerinden sınıflama, regresyon, kümeleme analizi, birliktelik analizi ve kontrol en çok tercih edilenlerdir. Sınıflamada amaç girdilerin katagorisinin belirlenmesidir. Verilen saç örneğinin kıvrıkcık, düz, ince telli gibi katagorize edilmesi sınıflamaya örnek verilebilir. Regresyon da açıklayıcı özelliklerden faydalanarak bir değer kestirilmesidir. Hava durumu değerleri dikkate alınarak hasta geliş sıklığını belirlenmesi regresyona örnek verilebilir. Kümeleme analizi, benzerliklerin bir grup altında toplanması şeklinde tanımlanmaktadır. Kümeleme analizinin kullanımına müşteri çeşidi örnek olarak verilebilir. Aynı harcama tipine yakın olan müşteriler aynı kümeye konulabilmesi kümelemeye örnek olarak verilebilir. Birliktelik analizi, eylemleri kümeleyerek yeni eylem önermesi olarak tanımlanmaktadır. Geçmiş satın alma değerleri kullanılarak, yeni satın alma önerilerinin yapılması birliktelik analizine örnek verilebilir. Kontrol için en iyi örneğin sürücüsüz otomobillerde amaçlanan uygulamaların kontrolünün olduğu görülmektedir. Makine öğrenme algoritmalarında, stokastik meyilli azalım algoritması yoğun olarak kullanılmaktadır. Bu algoritma ile belirli bir noktada kayıp fonksiyonunun türevi alınarak negatif veya pozitif değerine göre gradyan değerleri kullanılmaktadır. Bu sayede eğim en aza indirgenerek kayıp fonksiyonu da en aza indirgenebilir (Gürsaka, 2017).

En çok kullanılan makine öğrenme algoritmalarının bazılarını aşağıdaki biçimde tanımlayabiliriz.

1. Karar ağacı (Decision Tree): Karar ağacı algoritması genel olarak sınıflandırma için kullanılsa da regresyon için de kullanıldığı bilinmektedir. Karar ağaçları akış şemasına benzer. Bir kökten

başlayarak özelliklerine göre yayılıp bir ağaç şeklini alan algoritmalara karar ağaçları denilmektedir. En önemli faydası, hangi özneliliğin tahmini ne kadar açıkladığını göstermesidir.

2. Destek vektör makine algoritması (Support Vector Machine): Sınıflandırma ve regresyon alanlarında kullanılmaktadır. Açıklayıcı özellikler çok fazla olduğunda daha iyi sonuç verir ama örneklerin sayısı açıklayıcı özelliklere göre az ise iyi sonuçlar vermemektedir.
3. En yakın k komşuluğu (K-Nearest Neighborhood): Denetimsiz en yakın k komşu algoritması birçok algoritmanın temelini oluşturmuştur. Denetimli en yakın k komşuluğu algoritması ise hem regresyonda hem sınıflandırmada kullanılabilir. Çalışma prensibi yeni bir nokta geldiğinde buna en yakın k noktayı bulup yeni bir etiket tahmin yapmasıdır. Kesikli değişken yerine sürekli değişken veri etiketleri olduğunda kullanılması önerilir.
4. Lojistik regresyon (Logistic Regression): Bu algoritma özellikle sınıflandırmada kullanılmalıdır. Logit fonksiyonunu verilere uydurarak, var ya da yok gibi sonuçlara ulaşılabilir. Piyasanın, yönü aşağı veya yukarıya, kanser veya değil gibi tahmin konularında özellikle kullanılabilir. Birleştirme yapılarak diğer algoritmalarla birlikte kullanılırsa, diğer algoritmanın etkinliğini de yükseltebilir.
5. Rastgele orman (Random Forest): Tek bir karar ağacı ile sınıflandırmak yerine, bir çok karar ağacından faydalanılarak, sonrada bu ormandan alınan verileri tekrar sınıflandıran bir makine öğrenme algoritmasıdır.
6. Adaboost: Her bir öğrenmede hatanın çok olduğu yere odaklanıp, tekrar ağırlıkları düzeltip ikinci bir deneme yapar. Bu şekilde kayıp fonksiyonunu minimize etmeye çalışır. Boosting metot'u çok

kullanılan yöntemlerden birisidir. Başka yaygın bir metodu da gradyan artırımıdır.

7. Gradyan Artırma (Gradient Boosting): Boosting yaparken, zayıf öğrenenler gradyan iniş modeli ile desteklenir. Tahmin konusunda iyi sonuçlar vermektedir.
8. Stokastik gradyan iniş (Stochastic gradient descent): Gradyan azalma algoritmalarından biridir. Çok hızlı çalışan ve optimizasyonda iyi sonuç veren bir algoritmadır. Çok kolay uygulanabilir, fakat öznitelikler hakkında herhangi bir sonuç veremez.
9. Çok katmanlı algılayıcılar (Multilayer perceptron): Denetimli bir öğrenme algoritması olup, girdiler ile çıktılara ulaşmaya çalışan bir fonksiyon geliştirilir. Kayıp fonksiyonunu minimize etmek için stokastik gradyan iniş algoritmasının faydalandığı iki algoritmadan biridir. Karmaşık veri ilişkilerinde iyi sonuç vermektedir.

Makine öğrenme algoritmaları ve yapay sinir ağlarının başarısı özellikle veri yapısında açıklayıcı özellik olan öznitelik yapısına bağlıdır. Özniteliklerin seçimi ve hangi öznitelik kombinasyonun kullanılacağı tahmin başarısını çok etkilemektedir.

1.5. Öznitelik Seçimi (Feature selection)

Bir tahmini veya sınıflandırmayı yapabilmeniz için kullanılacak ayırt edici özellikler özniteliktir. Günleri ele aldığımızda, o günün hafta içi veya hafta sonu olması, resmi tatil ya da dini tatil olması gibi nitelikler o güne ait özniteliklerdir. Öznitelikler, açıklayıcı özelliklerinden dolayı makine algoritmalarına yol gösterirler. Makine algoritmaları ağırlık vererek ve bu ağırlıkları değiştirerek tahminle gerçek arasındaki farkı en aza indirmeye çalışırlar. Öznitelikler, denetimli makine öğrenmelerin en önemli aracıdır. Öznitelik kümesinin doğru seçimi, öznitelik sayısının fazla olmasından daha önemlidir.

Gereğinden fazla sayıda seçilen öznitelikler, hesaplama zamanını arttırırken, diğer özniteliklerin etkisini de azaltabilirler. Az sayıda öznitelik de açıklayıcı özellik yetersiz olacağından algoritmanın iyi sonuç vermesini engeller. Öznitelik seçimi, sistemin aşırı eğitilmesi sonucu, ezbere başlaması ve ezber sonuçların ortaya çıkmasını engellemek, algoritmanın çıktılarının doğruluğunu arttırmak ve hesaplama zamanını en aza indirmek için çok önemlidir. Öznitelik seçiminde, algoritmayı doğru sonuca ulaştıracak tüm açıklayıcı özellikler belirlenmeli ve toplanmalıdır. Daha sonra da bu öznitelik kümesinden en iyi sonucu verecek alt küme belirlenmelidir. Bu alt küme belirleme işinin birçok yöntemi bulunmaktadır. Filtreleyici ve sarmal yöntemler bunların en başında gelmektedir. Bu çalışmada sarmal yöntem kullanılmıştır. Sarmal yaklaşımda arama algoritmasının seçtiği alt küme bir sınıflandırma algoritmasıyla birlikte çalıştırılır. Bu şekilde sınıflandırma algoritmasının tahmin oranını yükselten öznitelikler tutulurken diğerleri çıkartılır. Bu ekleme çıkartma bir arama algoritmasıyla birlikte gerçekleştirilir. Filtreleyici yöntemde genelde korelasyon değerleri temel alınarak, öznitelikleri eleme yöntemiyle azaltan bir yöntemdir. Her iki yöntemde de elde edilen alt kümenin sınıflandırıcı performansını her zaman arttırdığı söylenemez. Filtreleyici ve sarmal metotları karşılaştırdığımızda, filtreleyici metodun zayıf olduğunu görürüz (Blum ve ark,1997). Korelasyon katsayılarını kullanan sarmal yöntemler daha hızlı çalışmakta ve daha iyi öznitelik alt kümesi oluşturmaktadır (Kabir ve ark, 2008). Bu çalışmada kapsamlı sarmal yöntem (exhaustive wrapper method) kullanılmıştır. Bu yöntemde alt kümelerin tamamı oluşturulur ve her alt küme denenerek en iyi sonucu veren alt küme o verinin ideal öznitelikler alt kümesini oluşturur. Bu seçim tartışmasız en doğru öznitelik seçimidir. Hesaplama zamanının fazla olmasından dolayı, bazen kapsamlı sarmal yöntem kullanılamaz ve diğer metotlardan faydalanılır.

1.6. Problemin Tanımı

Acil servislerde hızlı ve kaliteli hizmet sunabilmek için doktor, hemşire, sağlık teknisyeni gibi insan kaynaklarının ve acil servislerde bulunan hastane yatağı gibi diğer fiziki kaynakların etkili bir biçimde yönetilmesi gerekir. Bu kaynakların gereğinden az olması durumunda hastaların bekleme sürelerinin artması, acil servislerde yoğunluğun, hasta memnuniyetsizliğinin artmasına ve sunulan sağlık hizmetinin kalitesinin düşmesine neden olacaktır. Kaynakların fazla olması ise hastane işletme maliyetlerinin artmasına ve kaynak israfına neden olacaktır. Kaynak yönetimini etkili bir biçimde yapabilmek için acil servise gelen hastaların geliş sıklığı, muayene olmak için ortalama bekleme süreleri, muayene süreleri ve hastanın hastanedeki gözlem süreleri gibi parametrelerin tahmin edilmesi gerekir. Ancak bu parametreler doğası gereği belirsizliğin çok fazla olduğu parametrelerdir. Günün farklı saatlerinde acil servislere gelen hasta sayısının değişkenlik göstermesi, hastaların gözlem süresinin hastadan hastaya değişmesi gibi durumlar bu belirsizliklere örnek olarak verilebilir. Tüm bu belirsizliklerin öngörülmesi ve buna göre de kaynak optimizasyonu yapılması, daha az maliyetle yüksek kalitede sağlık hizmeti alınabilmesi için son derece önemlidir.

Bu çalışmada, YSA kullanılarak bir hastanenin acil servisine gelen hasta sayıları tahmin edilmiştir. Acil servislere gelen hasta sayısının doğru tahmin edilmesi, bu birimin yatak kapasitesinin ve insan kaynaklarının planlaması açısından kritik bir öneme sahiptir. YSA ve makine öğrenmesi ile tahmin yapabilmek için, Adana'nın Ceyhan ilçesinde faaliyet gösteren Özel Çınar Hastanesinde gözlemler yapılmı, hasta girişleri ilgili kayıtlar alınmış ve bunlar kullanılabilir veriler olarak derlenmiştir. Öznitelikler için literatür taraması yapılmış olup ayrıca acil servis çalışanlarından bilgi alınmış ve öznitelikler belirlenmiştir. Seçilen öznitelikler için de gerekli veriler derlenmiştir.

Son yıllarda YSA bir çok alanda iyi sonuç vermesi nedeniyle, bir çok araştırmacı belirsizliğin fazla olduğu acil servis gibi, sağlık sistemlerinde de YSA kullanarak talep tahmini yapmaya başlamışlardır. Bu tahmin aynı zamanda 9

makine öğrenmesi yöntemi ile de yapılmış olup, en iyi tahmin sonuçları simülasyona girdi parametresi olarak kullanılmıştır. Simülasyon modelinin başarısı gerçek sisteme benzerliğiyle doğru orantılıdır. Simülasyon modelinde kullanılacak hasta tedavi süresi, gelen hastanın hangi hastalık şikayeti ile geldiği, hangi işlemlerden geçtiği bu işlemlerin süresi gibi verilerde hastane personeli ve yönetimi ile görüşülerek, kısmen hastane kayıtlarından kısmen de hastanedeki gözlemler yoluyla toplanmıştır. Kaynak optimizasyonu için geliştirilen simülasyon modellemesinde, bu veriler kullanılarak acil servisteki en önemli kriter olan yatak sayısı belirlenmiştir.

1.7. Çalışmanın Amacı

Bir toplumun refah içinde yaşaması ve mutlu olması için her şeyden önce sağlıklı olması gerekmektedir. Sağlık hizmetleri ağırlıklı olarak hastanelerde verilmektedir. Birçok farklı hastaların geldiği, genelde ölüm ve kalıcı yaralanma riski taşıyan hastaların ilk müdahalenin yapıldığı acil servis birimleri, hastanelerde çok önemli bir yer tutmaktadır. Acil servislerde verilen hizmet ile ölümler ve kalıcı yaralanmalar önlenmekte ve özellikle ameliyat gerektiren durumlarda ilk tedavinin yapıldığı yer olduğundan acil servisler bir toplumun sağlık seviyesinin yükseltilmesi açısından en önemli yerlerdir. 24 saat kesintisiz hizmet vermesi, her türlü hastalıkla mücadele etmesi ve saniyelerin değerli olduğu bu servis birimleri hastane bütçesinden çok fazla pay almaktadır. Toplumun sağlık seviyesini yükseltebilmek için acil servis birimlerinde verilen sağlık hizmet kalitesinin yükseltilmesi gerekmektedir. Özellikle bütçe sıkıntısı olan gelişmekte olan ülkelerde kaynak optimizasyonu yapılarak, az bütçeyle sağlık hizmetinin seviyesinin yükseltilmesi gerekmektedir. Bu çalışmada kaynak optimizasyonu problemini çözebilmek için bir simülasyon modeli geliştirilmiştir. Geliştirilen modelde girdi parametreleri kullanmak üzere YSA ve diğer makine öğrenme metotları ile hasta geliş sıklığı tahmin edilmiştir. Simülasyon modeli için diğer gerekli veriler de toplanarak yatak sayısı belirlenmiştir. Kurulan modelde acil

servislerde kaynak belirlenmesi yapılarak az bütçeyle yüksek seviyede kalite verilmesi amaçlanmıştır.

1.8. Çalışmanın Kapsamı

Çalışmada irdelenen problem, aşağıdaki kapsamda ele alınmıştır:

1. Geliştirilen model acil servisler için tasarlanmıştır.
2. Acil servisle ilgili kayıtlardan 5 yıllık veriler saatlik ve günlük olarak elde edilmiştir.
3. Öznitelikler bu verilerde saatlik ve günlük olarak belirlenmiştir.
4. Hastanedeki tüm poliklinikler ve doktorlar bu çalışmaya destek sağlamışlardır.
5. Gelen her hastanın, tedavi görmeden hastaneyi terk etmediği kabul edilmiştir.

1.9. Çalışmanın Özgün Katkısı

Sağlık hizmetlerinin öneminden dolayı bu hizmetlerin kalitesini yükseltmek için çok fazla çalışma yapılmıştır. Bu çalışmanın en önemli katkılarından biri, ideal kaynak sayısının belirlenmesi amacıyla geliştirilen simülasyon modeline girdi sağlamak için makine öğrenme algoritmalarından faydalanılmasıdır.

Bu çalışmada makine öğrenme algoritmaları kullanılarak, hasta geliş sıklığı tahmin edilmiş ve bu tahmin simülasyon modelinde girdi parametresi olarak simülasyon modelinde kullanılmış ve acil servis biriminde ihtiyaç duyulan yatak sayısı belirlenmiştir. Çalışmanın bir diğer katkısı da bu tahminin LSTM modeli ile yapılmasıdır ki literatürde bu metotla yapılan ikinci çalışmadır. Son olarak ise öznitelik kümesinin optimizasyonu yapıldı ki, bu hasta geliş sıklığını tahmin eden çalışmaların hiçbirinde daha önce yapılmamıştır.

Ayrıca, hasta geliş sıklığını saatlik tahmin edilmesi yönüyle bu konuda yapılmış ender çalışmadan biridir. Çalışmada gerçek veriler kullanılmış olup, aynı çalışmanın içinde saatlik tahmin, yıllık tahmin ve 5 yıllık tahmin yapılmıştır. LSTM metodu ile birlikte 9 makine öğrenmesi yöntemi kullanılarak tahminler yapılmış ve en iyi çıktı simülasyon modelinde girdi parametresi olarak kullanılmıştır. Yukarıdaki özelliklerinden dolayı hasta geliş sıklığı tahmininin simülasyon modelinde girdi parametresi olarak kullanılması ile literatürdeki boşluğun doldurulması amaçlanmaktadır.

1.10. Çalışmanın Adımları ve Organizasyonu

Bu bölüm, takip eden iki alt başlık altında incelenmiştir.

1.10.1. Çalışmanın Adımları

Çalışmanın adımları aşağıdaki biçimdedir.

1. *Problem belirlenmesi:* Sağlık hizmetlerine katkı yapabilmek amacıyla bu problem belirlenmiştir. Bu problemin çözümü için gereken tüm veriler, geliştirilmesi gereken modeller belirlenmiş ve amaçlar net bir şekilde ortaya konmuştur.
2. *Literatür incelemesi:* Problemin çözümüne yönelik önceki çalışmalar incelenmiş, literatürdeki eksiklikler tespit edilmiştir.
3. *Model geliştirilmesi:* Bu çalışmada iki model geliştirilmiştir. Öncelikle simülasyon modeline girdi olarak verinin tahmini için yapay sinir ağları ve diğer 9 makine öğrenme algoritmasının mimarisi belirlenmiştir. İkinci adımda buradan alınan verilerin kullanımı için simülasyon modeli geliştirilmiştir.
4. *Vaka çalışması:* Geliştirilen model, çalışmanın özgün katkılarından biri olan Ceyhan Özel Çınar Hastanesinde ki gerçek verilerle bir vaka çalışması için kullanılmıştır.

5. *Sonuçların değerlendirilmesi:* Elde edilen sonuçlar değerlendirilmiş ve yorumlanmıştır.
6. *Duyarlılık analizleri ve öneriler:* Özellikle makine öğrenme algoritmaların mimarisinde optimum parametreler bilinemediğinden, elde edilen sonuçlar ile kıyaslamak adına algoritmalarındaki birçok parametrede değişik kombinasyonlar oluşturularak duyarlılık analizleri gerçekleştirilmiştir. Simülasyon modelinde parametrelerde değişiklik yaparak gelecek çalışmalar için öneriler sunulmuştur.

1.10.2. Çalışmanın Organizasyonu

Çalışmanın ikinci bölümünde, ilgili başlıklar altında konunun detaylı bir literatür incelemesi yapılmıştır ve bu çalışmalar özetlenmiştir. Üçüncü bölümde çalışmada kullanılan materyal ve metot açıklanmıştır. Bu bölüm verinin toplanması, verinin sunulması ve model geliştirmeyi (Makine öğrenme algoritmaları ve Simülasyon modeli) içermektedir. Geliştirilen model, gerçek verilerin alındığı hastanenin acil servisinde yatak sayısının belirlenmesi probleminde çözüm bulmak için kullanılmıştır. Dördüncü bölümde geliştirilen modelin sonuçlarını, yorumlarını ve analizlerini kapsamaktadır. Son bölümde de sonuçlar ve öneriler sunulmuştur.



2. ÖNCEKİ ÇALIŞMALAR

Çalışmada ele alınan konu ile ilgili detaylı bilgilere ulaşmak, konuyu daha iyi anlayabilmek ve literatürdeki eksikleri belirleyip bu konuya özgün bir katkıda bulunmak için detaylı bir literatür çalışması yapılmıştır. Çalışma hem hasta geliş sıklığını tahmin etmeyi, hem de bu tahminleri geliştirilen simülasyon modelinde kullanarak kaynak optimizasyonunu hedeflediği için literatür çalışması da iki ayrı başlık altında yapılmıştır. Öncelikle tahmin etme yöntemleri ve daha sonra da simülasyon yöntemleriyle acil servislere kaynak tahsisi ve optimizasyonu ile ilgili çalışmalar incelenmiştir. Tahmin etme yöntemi ile ilgili makalelerde hasta geliş sıklığı ve kalış süresini tahmin etmeye yönelik çalışmalar ve aynı zamanda bu gözetimli makine öğrenmesinin başarısını sağlayan öznelik seçimi üzerine yapılan çalışmalar incelenmiştir. Simülasyon ile ilgili çalışmalarda, özellikle kesikli olay simülasyonunu konu alan ve acil servisin işleyişini inceleyen araştırmalar incelenmiştir.

2.1. Tahmin Etme Yöntemleri ile İlgili Çalışmalar

2.1.1. Hasta Geliş Sıklığı ve Hasta Kalış Süresi ile İlgili Çalışmalar

Literatür araştırmasının bu kısmında, hasta geliş sıklığını inceleyen çalışmalar ve kalış süresini tahmin eden çalışmalar incelenmiştir. Kaynak tahsisinin ve iyileştirilmesini yapabilmek için hastaların geliş sıklığını ve kalış süresini bilmemiz gerekmektedir. Bu öngörüye sağlıklı ulaşabilmemiz için kullanacağımız model kadar öznelik kümesinde önemlidir. İyi bir planlama yapılabilmesi için olabildiğince kısa vadeli mümkünse saatlik bazda tahmin yapılması gerekmektedir. Fakat tahmin süresi kısaldıkça tahmin yapmak zorlaşmaktadır. Yapay sinir ağları ve makine öğrenmesi modelleri tahmin konusunda diğerlerinden oldukça iyidir. Yalnız, yapay sinir ağları ile yapılan tahmin modellerinin modeldeki mimari yapıya çok hassas olduğu, bu sebeple modeller arası üstünlük tartışılırken bu

konunun dikkate alınması gerektiği literatürde belirtilmektedir. Bu konudaki çalışmalar aşağıda sunulmuştur.

Mc Carthy ve ark. (2008), literatürde saatlik olarak çok az çalışma bulunan acil servise gelen hasta sıklığını öngörmeyi amaçlamışlardır. İklimle ait, zamansal ve hastalara ait özellikleri bir fonksiyon olarak kullanarak saatlik hasta sayısını Poisson olasılık dağılımını kullanarak, öngörü de bulunmaya çalışmışlardır. 8760 saatlik bir veriyi ele alarak da bu tahmini gerçekleştirmişlerdir.

Jones ve ark. (2008), ekonomik, endüstriyel ve stratejik planlama yaparken alınacak kararların doğru olması için doğru tahminlere çok ciddi ihtiyaç olduğunu belirtmişlerdir. Özellikle sağlık sistemlerinde tahmin modellerinin çok az kullanıldığını tespit etmişlerdir ve 3 farklı hastanenin acil servisi ile ilgili 27 aylık günlük veri toplamışlar, bu verilerle de ARIMA, üssel düzeltme ve yapay sinir ağları modellerini kullanarak tahmin çıktılarını ulaşılmışlardır. Bu çalışmada, genel kanıyı destekler nitelikte olup, hasta gelişlerinde mevsimsel ve haftalık döngü bulunduğunu tespit etmişlerdir.

Wargon ve ark. (2009), acil servislerdeki kalabalığı önlemek ve hasta geliş sıklıklarını belirleyerek kaynak tahsisini optimize etmeyi amaçlayan çalışmaları incelemişlerdir. Birçok modelin takvim verilerini kullanarak regresyon modelleriyle ya da zaman serileriyle tahmin yaptığını, günlük tahminlerde 4,2-14,8 % başarıya ulaşıldığını, hava durumu verilerinin tahmin performanslarını düşürdüğünü ifade etmişlerdir. Performans ölçümlerinde, ortalama mutlak hata yüzde oranı, ortalama hata kareleri karekökü, regresyon analizlerinde yüzde değişiklik oranı kullanılmıştır. Bu çalışmada modeller arasında bir üstünlük bulunmamıştır, Takvim verilerini kullanarak tahmin yapan ve ortama mutlak hata yüzde oranını performans ölçüsü yapan modellerin çok daha kolay anlaşılır olduğunu belirtmişlerdir.

Abraham ve ark. (2009), hastane çalışanlarının kaynakları etkin kullanmak ve aynı zamanda yüksek seviyede sağlık hizmeti vermek zorunda olduğunu, bunun

için de kapasitenin doluluk oranını bilmek gerektiğini belirtmiş, bunun için acil servise geliş sıklığının kısa vadeli tahminini yapmak istemiştir. Bunun için 3 yıllık günlük veri ile tahmin yapabilmek için mevsimsel ARIMA algoritmasını ve yapılan tahminin performansını ölçmek için ortalama hata kareleri formülünü kullanmışlardır. Yapılan tahmin sonucu, hasta geliş sıklığının oldukça tesadüf ve tahmin edilemez olduğunu belirtmişler. Yalnız doluluk oranının tahmin edilebileceğini fakat bunun da 1 haftadan fazla olmayan bir süre için yapılabildiğini ifade etmişlerdir. Bu çalışmanın birçok kısıtlarına rağmen yine de hastane yönetimi için kaynak planlamasında ve kalabalığı azaltmada faydalı olabileceğini ifade etmişlerdir.

Sun ve ark. (2009), mikro ve makro seviyede kaynak planlaması yapmak için acil servislere geliş keskinlikle tahmin edilebilmesinin çok faydalı olacağını belirtmiştir. Bu amaçla, 3 yıllık veri toplanmıştır. Hastaların acil seviyesine göre 3 gruba ayırmışlardır, ARIMA metodu 3 sınıfa ayrı ayrı ve aynı zamanda tüm hastaların grubuna uygulanmıştır. Öznitelik olarak resmi tatiller, ortam hava kirliliği indeksi gibi veriler kullanılmışlardır. En acil sınıf için yapılan tahminlerde, bağımsız verilerle bir ilişki kurulamamıştır. İkinci grup için, haftalık bir döngüyle ve resmi tatillerle ilişki kurulabilmiştir. Üçüncü grup için ise, haftanın günü, ayı mevsim, hava kirliliği ve tatil günleri ile tamamen ilişkili davranış sergilediğini gözlemlemişlerdir. Yapılan tahmin çalışmalarında performans ölçü kriteri olarak ortalama mutlak yüzde hatası kullanmışlardır ve sırasıyla %16,8, %6,7, %8,6 ve tüm grup içinde %4,8 olarak sonuç bulmuşlardır. Acil servislerdeki hastanın acil önem derecesi arttıkça, belirsizliğin de arttığını belirtmişlerdir.

Boyle ve ark. (2011), acil servislerdeki hasta geliş sıklığını tahmin etmeyi amaçlamışlar, bu sayının tesadüf olmadığını tahmin edilebileceğini ifade ederek tahmin çalışması yapmışlar ve tahmin edilen süre azaldıkça tahmin başarı oranının düştüğünü ifade etmişlerdir. Aylık, günlük, 4 saatlik ve 1 saatlik tahminlerde bulunmuşlar ve OMYH performans ölçüm değerine göre sırasıyla, %2, %11, %38

ve %50 oranına ulaşabilmişlerdir. Bu da genellikle hasta geliş sıklığı konusunda yapılan çalışmaların yüzdelere yakındır. Farklı iki ayrı hastaneden 5 yıllık kayıt almışlar ve ilk öngörü çalışmalarını bu hastanelerin verileri ile yapmışlar ve daha sonra doğrulamak için 27 ayrı hastane ile çalışmışlardır. Tahmin yöntemi olarak ARIMA, çoklu regresyon ve üssel düzgünleştirme kullanılmışlardır. Aynı çalışmanın hastanelerdeki yatak yönetiminde veya ameliyathanenin programının yapılmasında, stratejik planlar yapılabileceği böylece sağlık kalitesinin yükseleceğini bundan hem sağlık personelinin hem de hastaların fayda sağlayacağını ifade etmişlerdir.

Bergs ve ark. (2013), 4 farklı Belçika hastanesinden 6 yıl boyunca aylık hasta geliş verisi derlemiş ve bu verilerden faydalanılarak, otomatik üssel yumuşatma yöntemi ile tahminlerde bulunmuşlardır. Bu tahminlerde %4,86-2,64 OMYH oranı ile başarı sağlamışlardır. Buldukları bu sonuçtan stratejik kararların alınmasında faydalanılabileceğini, fakat aylık tahminlerin insan kaynağının planlanması konusunda çok az faydalı olduğunu da belirtmişlerdir.

Xu ve ark. (2013), acil servislerde kalite seviyesini gösteren en önemli iki unsurun hastaların bekleme süresi ve hastaların taburcu süresi olduğunu ve bu iki unsuru etkileyen en önemli faktörün de hasta geliş sıklığı olduğunu belirtmiştir. Hasta geliş sıklığının öngörmek için, yapay sinir ağları, doğrusal olmayan en küçük kare sistemi ile regresyon ve çoklu doğrusal regresyon modelleri ile tahmin yapmışlar ve yapay sinir ağlarının en iyi sonucu verdiğini tespit etmişlerdir. Öznitelik seçiminde hem zamana bağlı hem de hava durumuna bağlı nitelikler kullanmışlardır. Öznitelikler ve hasta geliş sıklığının korelasyonlarına bakarak çözümleme yapmışlar ve hastaları acil önemine göre sınıflandırmışlardır. 12 aylık veriye dayanan veriyle hasta geliş sıklığını günlük olarak tahmin ederek, hastane yönetiminin kaynak planlaması gibi konulardaki karar sistemine destek olunmasını amaçlamışlardır.

Kortbeek ve ark. (2014), büyük ameliyathane çizelgelemesi ile acil servise gelen hasta sıklığının bir fonksiyonu olarak, hemşire hizmeti ihtiyacı duyan yataklı hasta sayısını tahmin etmek için genel analitik bir yaklaşım sunmuşlardır. Bu tahminlerinde karar destek sistemin de kullanılarak, gerek ameliyathane de gerekse acil serviste ve bu bölümlerle ilişkili kısımlarda kaynak tahsisi ve çizelgeleme yapabileceğini ifade etmişlerdir. Buradaki tahmin sistemi öncelikle iki ayrı tahmin sisteminden beslenmekte sonra tek tahmin sistemine indirgenmektedir. Bu tahmin sistemlerinden biri ameliyathane diğeri acil servise gelen hastadır. Homojen olmayan Poisson dağılımı ile acil servise gelen hastaların ve kesikli bir dağılımla da ameliyathaneye gelen hasta sayısı tahmin edilmiş ve bu iki bilgi ile yatak sayısının belirlenmesinde kullanılmıştır.

Gül ve ark. (2015), acil servislerde hasta kalış süresini, yani hastanın acil servise gelişinden taburcu edilene kadar veya başka bir servise sevk edilene kadar geçecek sürenin tahmin edilmesinin kaynakların tahsis ve planlanması konusunda yardımcı olacağını düşünerek, hasta yaşı, cinsiyet, hastaneye geliş şekli, acil serviste uygulanan tıbbi testler ve muayene gibi öznitelikleri YSA girdi olarak kullanarak hasta kalış süresini öngörmeyi hedeflemişlerdir. Türkiye'nin doğu bölgesinde yılda 40.000 kişiye hizmet veren bir hastanenin acil servisinde 1.500 kişi ile bu çalışmayı gerçekleştirmişlerdir. Bu çalışma maalesef genelde tahmin modellerinde iyi olduğu düşünülen % 80 oranının altında başarı sağlamıştır. Bunun sebebinin ise seçilen öznitelikler olduğu düşünülmüştür.

Kortbeek ve ark. (2015), hemşirelik hizmetlerinin hasta geliş sıklığı ve kalış süresinden yanı kısıcası hasta doluluk oranından çok fazla etkilendiğini, bunu dengelemek için iş yükünün önceden tahmin edilmesi ve buna göre de personelin çizelgesinin ayarlanmasının hizmet kalitesini arttıracak yüksek maliyet oluşturacağını ifade etmişlerdir. Kortbeek'in 2014 yılında yaptığı çalışmada detaylı olarak anlatılan tahmin modeli ile saatlik yatak ihtiyacı hesaplanmıştır. Bu model kısa vadeli 3-5 günü belirliyor, bunu saatlik dilimlere bölüyor ve oraya olasılık

dağılımına göre yatak sayısı atıyor. Bu girdileri kullanarak stokastik bir yaklaşımla da hasta hemşire oranını düzenliyor. Bu tip bir karar destek modeli ile sağlık hizmetlerinin yönetilmesi gerektiğini ifade etmişlerdir.

Schiavo ve ark. (2015), çalışmalarında, hastane ortamında sağlık hizmet kalitesinin iyileştirilmesi için, bazı parametrelerin tahmin edilmesinin gerektiğini ve yapay sinir ağlarının bu konuda çok faydalı olduğunu göstermişlerdir. Matematiksel modellerin bu kadar karmaşık bir sistemi analiz edemediğini, ama kullanılan çok geniş veri kümesinin yapay sinir ağları ile değerlendirilip, hastane hizmetlerinin kalitesini yükseltmeye faydalı olacak sonuçlar verdiğini belirtmiştir.

Gholipour ve ark. (2015), son zamanlarda yapay sinir ağlarının hasta tahmini konusundaki başarılı katkılarının, klinik tıpta iyileşmelere sebebiyet verdiğini belirtmiştir. Yapay sinir ağlarını yoğun bakımda hayatta kalma oranı ve yatış süresini tahmin etmek için kullanarak, yoğun bakımda önleyici tedbirlerle, sağlık kalitesini yükseltmeyi amaçlamıştır. Klinik ve biyokimyasal veriler öznitelik olarak kullanılmış ve tatmin edici öngörü çıktılarına ulaşmışlardır. Sonuç olarak, yaptıkları çalışma sonucunda elde edilen verilerin ışığında, yapay sinir ağlarının yakın gelecekte tahmin modellerinde çok fazla kullanım potansiyeli olduğunu ifade etmişlerdir.

Golmohammadi (2016), hastanelerdeki acil servislerde kalabalığın oluşma sebebi, hastaların doğru zamanlamayla yataklara yerleştirilememesi olduğunu, bu kalabalık problemin çözümünün hasta geliş sıklığının tahmin edilebilmesi olduğunu belirtmişler ve bunun için hastane çalışanlarına karar destek modeli olabilecek bir tahmin modeli geliştirmişlerdir. Bu tahmin modeli için, 8 tane öznitelik belirlemişler ve bunlardan en önemlilerinin yaş ve radyoloji muayenesi olduğunu tespit etmişlerdir. Bu öznitelikleri kullanarak, sinir ağları ve lojistik regresyon modelleri ile çalışma yapmışlardır. Bu çalışmada hastane birimlerinin, acil servis de dahil olmak üzere birbiriyle çok iyi iletişim için de olması gerektiğini entegre olmalarının gerekliliğini sadece kendi birimlerinin çıktısına odaklanmadan

tüm sistemi göz önünde bulundurularak yönetimin gerçekleştirilmesini ve bölgesel optimizasyondan kaçınılması gerektiğini ifade etmişlerdir. Bu çalışmada ayrıca bazı diğer çalışmaların aksine evlilik durumu ve gelinen günün öznitelik açısından hiçbir etkisi olmadığı tespit edilmiştir.

Lee ve ark. (2017), öngörü modellerinden çok katmanlı algılayıcılar ile derin öğrenme modellerini karşılaştırmak istemişler, deneysel inceleme yapmışlar ve basit algoritmalarla değil de daha karmaşık algoritmalarla daha az hata verecek tahmin modeli bulmak istemişlerdir. Endeksi tahmin etmişler ve derin öğrenmenin daha iyi sonuç verdiğini gözlemlemişler, ama aradaki farkın kayda değer olmadığını ifade etmişlerdir. İki tahmin metodunda da aylık öngörü tahminleri haftalık öngörülerden daha iyi olmuştur. tahmin aralığı genişledikçe tahmin keskinliği artmaktadır. Yalnız, bu çalışmada da yapay sinir ağları ile yapılan tahmin modellerinin modeldeki mimari yapıya çok hassas olduğu ve bu sebeple modeller arası üstünlük tartışılırken bu konuyu da dikkate almak gerektiğini belirtmişlerdir.

Lucini ve ark. (2017), acil servislerde aşırı kalabalık problemini çözmek için, yatak talebini kısa bir zaman öncesinden öngörerek, hastanede aşırı kalabalığı en aza indirmek ve diğer kaynakların optimizasyonunu amaçlamışlardır. Bu amaçla metin analizinde kullanılan 8 adet makine öğrenme algoritmasından faydalanmışlardır. Hastaların tedavi öncesi metin kayıtlarını inceleyerek öznitelikler oluşturulmuştur. Öznitelik seçiminde x kare ve F skor metriği testini kullanmışlardır. Nu-destek vektör makine algoritması diğer algoritmalara tahmin konusunda üstünlük sağlamışlardır. Bu yöntemle acil servis de günlük planlamalarının yapılabileceği, kapasite planlaması ve kaynak tahsisi yapılabileceğini ifade etmişlerdir.

Silva ve ark. (2017), acil servislerde belirsizlik probleminin, sağlık hizmetinin kalitesini düşürdüğünü ve yönetimini zorlaştırdığı için, hasta geliş sıklığını tahmin etmek istemişlerdir, Portekiz’de Braga hastanesinde 2 yıllık gerçek

veri ile yürüttükleri bu çalışmada, Forecastpro yazılımı kullanılarak ARIMA modeli ile tahmin gerçekleştirilmiştir. Acil servisteki kaynak kullanımının çok karmaşık olmasından dolayı, kaynak planlamasının verimli yapılabilmesi için öngörülerin gerçekçiliğinin çok önemli olduğunu, tahmin modelinin yatak tahsisini optimize etmeye yaradığını ifade etmişlerdir. Haftalık tahminlerde OMYH 5,62% gibi oranda başarılı olmuştur. Yatak tahsisinin doğru yapılmasının, ayrıca insan kaynağının da doğru planlanmasına ışık tuttuğunu ifade etmişlerdir. Bu çalışmanın orijinal katkısı, hasta geliş sıklığının tahminin, gerçek verilerle yapılmış olması olup, 350.000 adet hasta geliş verisi kullanılmıştır. Bu çalışmadan önce gerçek verilerle yapılmamıştır.

Hong ve ark. (2018), 560,486 hastanın acil servise gelişini veri olarak incelemiş, bu verinin %80 eğitimde %10 doğrulamada ve %10 da test için kullanmış olup, 3 ayrı makine öğrenmesi ile, lojistik regresyon, gradyan artırımı ve derin öğrenme ile tahmin etme yoluna gidilmiştir. Birinci grupta acil önemine göre sıralama bilgileri, ikinci grupta hastaya ait bilgiler ve üçüncü grupta tüm bilgileri ele almışlardır. Birinci grup ve ikini grup bilgileriyle yaklaşık aynı keskinlikte tahmin sonucu bulunurken, acil önem sırasının bilgilerine hasta ile ilgili bilgiler eklenince tahmin tutarlılığı %4 artmıştır. Bu çalışma ile de makine öğrenme yöntemlerinin hasta geliş sıklığı konusunda kesinlikle başarılı sonuçlar verdiğini göstermişlerdir.

Graham ve ark. (2018), acil servislerdeki aşırı kalabalık sorunun sağlık hizmet kalitesini olumsuz yönde etkilemesinden dolayı, hasta geliş sıklığını yönetmek için yenilikçi metotlardan faydalanılması amacıyla makine öğrenme algoritmalarını kullanarak hasta geliş sıklığını tahmin etmiş acil servislerdeki bu aşırı kalabalık sorunu çözmek istemişlerdir. Makine öğrenme algoritmalarından, karar ağacı, lojistik regresyon ve gradyan artırım algoritmaları kullanılmış ve bu algoritmanın çok iyi performans gösterdiğini belirtmiştir. Öznitelik olarak zamansal özellikler ve aciliğine göre sıralama bilgileri kullanılmıştır. Bu

çalışmanın amacı da hasta geliş sıklığını öngörerek, planlamaların ve yönetim kararlarının daha doğru verilmesidir.

Stewart ve ark. (2018), acil servis de yapay zeka ve makine öğrenmesi konusunda inceleme yapmışlardır. Yapay zekanın geçmiş yıllarda çok hızlı gelişmesi, büyük veri kümelerinin olması ve bilgisayarların gücünün çok artması ile, modern makine öğrenme algoritmalarının ve özellikle derin öğrenmenin çok fazla başarıya imza attığını belirtmişlerdir. Acil servis de klinik takip ve hatta ev de takip yaparak çok fazla veri elde edebileceğini ve hasta ya yardımcı olacak sonuçlar çıkarabileceğini belirtmişlerdir. Ayrıca, görüntü analiz yapabilmesinden dolayı, göğüs röntgenleri gibi birçok verinin bilgisayara yüklenmesi ile teşhis konusunda da yararlanılabileceğini belirtmişlerdir. Yapay zekanın hızlı karar verebilmesi gibi bir çok özelliğinden faydalın dolayı, acil servislerde birçok klinik problemin çözümünde yararlanılabileceğini ifade etmişlerdir.

Parker ve ark. (2018), acil servislerdeki kalabalık probleminin gittikçe artan uluslararası sağlık meselesi olduğunu, kalabalık sorununun yatak talebi olan hastanın müdahale edilemeden bekleme süresini arttırdığını ifade etmişlerdir. Bu çalışma hastanın acil önem sırasına ait bilgiler alındıktan sonrası ihtiyacını öngörmek üzere yapılmıştır. Bu da onlara öznitelik açısından, hastanın yaşı, ırkı, posta kodu, tirajdaki kodu ve ateş durumu gibi açıklayıcı özellikleri zamansal değerlere bağlı özniteliklerle kullanılmasına imkan sağlamıştır. Bu sayede girdi bilgileri demografik, yönetsel ve zamansal olmak üzere oldukça farklı temellerde açıklayıcı özellik içermiştir. Singapur'da ki bir hastaneden 10 yıllık veri kullanılmış olup, tahmin yöntemi olarak da lojistik regresyon ve kullanılan yöntemin hassaslığını tespit edebilmek için de ROC eğrisinden faydalanmışlardır. AUC performansları 0,825 olarak gerçekleşmiş olup, bu modelin avantajlı tarafı modelin klinik verisini çok az kullanmasından dolayı tahmin işlemini oldukça hızlı yapabilmekte, bu da kaynak planlaması gibi yönetsel çalışmaların daha etkin olmasını sağlamaktadır.

Hertzum (2018), acil servislerde artan kalabalık problemini çözmek için aylık, haftalık veya günlük tahminlerin oldukça iyi performanslarla yapıldığını fakat acil servislere iyi planlama yapılabilmesi ve hatta sık sık beklenmedik olayların yaşandığı bu bölümlerde çizelgelemelerin tekrar tekrar oluşturulabilmesi için çok iyi performans gösterecek saatlik tahminlerin gerektiğini ifade etmişlerdir. Bu tahminleri yapabilmek için 2012-2014 yılları arasındaki veriyi modellerinde kullanmışlar ve 2015 yılının Ocak ayındaki hasta gelişi ve acil servis doluluğu tahmin edilmeye çalışılmıştır. Bunun için de öznitelik olarak takvim bilgilerini kullanmışlar, model olarak da ARIMA ile doğrusal regresyon modellerini seçmişlerdir. Hasta geliş sıklığını (47-58 %) olarak doğrusal regresyonla ARIMA metodundan daha iyi ölçerken, hastane doluluğunu ARIMA 69-73% hata oranı ile doğrusal regresyon metodundan daha iyi ölçmüştür. Zaman aralığı kısaldıkça tahmin zorluğunun arttığını ve takvimsel veriler yanında başka özniteliklerin de tahmin için kullanılması gerektiğini ifade etmişlerdir. Danimarka'nın 4 farklı acil servisinde yapılan bu çalışmada sonuçların benzerliği, çalışmanın bölgesel özelliklerden bağımsız olduğunu göstermiştir.

Jones ve ark. (2018), yaptıkları çalışmada makine öğrenme algoritmalarının ve geleneksel matematiksel modellerin hasta geliş sıklığını ve hastane doluluğunu tahmin etme performanslarını karşılaştırmışlardır. Gradyan artırma ağaçları, sinir ağları ve rastgele orman algoritmaları lojistik regresyon algoritmasının iki tipine karşı test edilmiştir. Burada acil servisle ilgili 3 çıktı tahmin edilmiş ve gradyan artırma ağacı ve sinir ağları diğer algoritmalara karşı üstünlük sağlamıştır.

2.1.2. Makine Öğrenme Algoritmalarında Öznitelik Seçimi ile İlgili Çalışmalar

Makine öğrenme algoritmalarının başarılı olmasındaki en önemli iki özellik, bir algoritmanın yapısı diğer bir deyişle mimarisi olmakla beraber, seçilen

öznitelik kümesi de çok etkili olmaktadır. Yalnız seçilen öznitelik kümeleri başlangıçta çok geniş olmakta bu hem makine öğrenmesinin çalışmasını uzatmakta hem de ideal kümeye erişilmediyse tahmin performansını düşürmektedir. Bunun için öznitelikle kümesinin olabildiğince küçük ve doğru belirlenmesi gerekmektedir. Bu amaçla ilgili çalışmalar incelenmiş ve aşağıda sunulmuştur.

Hall ve ark. (1999), öznitelik seçimi, makine öğrenmelerinin öğrenen tipleri için vazgeçilmez olduğudur. Özniteliklerin gereksiz olanlarının mutlaka öznitelik kümesinden çıkartılması gerektiğini belirtmişlerdir. Bu kümenin iyileştirilmesi, algoritmanın başarısını birebir etkilemektedir. En genel yöntemlerden biri sarmal diğeri filtreleme algoritmaları olup, sarmal algoritma kullanarak özniteliğin gerekli olup olmadığını söylemektedir. Bunun yanı sıra filtreleme algoritması sezgisel yöntemlerle verinin genel özelliğine uyumlu olanları seçmektedir. Bu makalede ise korelasyon temel alınmış sezgisel yöntemi kullanan bir filtreleme metoduyla çok daha iyi bir öznitelik kümesi bulunacağı ifade edilmiştir. Veri işleme sürecine uygulandığında iki makine öğrenme algoritmasından filtreleme metodunun sarmal metoda göre daha olumlu ve daha kısa süren hesaplama süresi ile çözüme ulaştığı görülmüştür. Bu korelasyon öznitelik yöntemine göre, çıktılarla çok fazla korelasyona sahip olan öznitelikler bu öznitelik kümesine dahil ediliyor, ama dahil edilen öznitelikler eğer birbiriyle de yüksek korelasyona sahiplerse biri hariç diğerleri kümeden çıkmakta ve böylelikle ideal bir öznitelik kümesine ulaşılmaktadır.

Guyon ve ark. (2003), çalışmalarında binlerce değişkenin arasında hangilerinin gerekli olduğunu belirlemek ve makine öğrenme algoritmalarının hesaplama zamanını ve sonuçlardaki hata farkını en aza indirmek gittikçe önem kazanan bir araştırma konusu olduğunu vurgulamışlardır. Yaptıkları çalışmada karmaşık zarfleyici modelin korelasyon gibi öznitelikleri derecelleyen metotlara göre her zaman çok büyük farklarla olmasa da ciddi farklarla daha iyi performans gösterdiklerini belirtmişlerdir. Sonuç olarak test için doğrusal bir algoritma

seçmemizi daha sonrada korelesyon veya başka bir değerlendirmesiyle öznitelikleri sıralamamızı, ileri veya geri seçim ile öznitelik altkümesinin seçilen algortmada test ederek en iyi alt kümeyi belirlememizi önermişlerdir.

Kabir ve ark. (2008), öznitelik kümesini belirlemek için yapıcı öznitelik seçimi yaklaşımı olarak adlandırdıkları ve yapay sinir ağları için kullanılabilecek bir yaklaşım geliştirmişlerdir. YSA’nda gizli nöron sayısını da belirlemek için kullanılabilecek bir yaklaşımdır. Özniteliklerin korelasyon bilgisinden faydalanılarak, benzer öznitelikler bir gruba toplanarak iki grup oluşturulmaktadır. 3 katmanlı ileri beslemeli yapay sinir ağı oluşturulur ve mimari deki diğer parametreler başlangıç değeri alır. Daha sonra her bir gruptan birer öznitelik alınır ve YSA çalıştırılır. Öznitelikler etkisiz ise elenir. Öznitelik seçiminde diğerleri ile korelasyonu en düşük olan öznitelik seçimde en öncelikli olandır. Bu şekilde eleme yapılırken öznitelik seçimi olmadığında gizli nöron eklenerek öznitelik gruplarında seçilmemiş kalmayana kadar devam edilir. Bulunan bu algortmanın diğer sarmal öznitelik seçim modellerinin hepsine tüm problemlerde üstünlük sağladığı ifade edilmiştir.

Ramaswami ve ark. (2009), öznitelik seçiminin makine öğrenme algortmalarının tahmin performanslarını çok etkilediğini belirtmiş, 6 filtreleme yöntemi uygulayarak çalışmalarında makine öğrenme algortmasının performanslarını gözlemlemek istemiştir. Korelasyon bazlı hesaplama, ki-kare testi öznitelik değerlendirmesi, kazanım oranı öznitelik değerlendirmesi, bilgi kazanımı öznitelik değerlendirmesi, yardım özelliği değerlendirilmesi ve simetrik belirsizlik özelliği değerlendirilmesi olarak 6 eleme metodu karşılaştırılmış olup, bilgi kazanımı öznitelik değerlendirmesi hepsinden başarılı olmuştur.

2.2. Acil Servislerde Kalabalık Sorununu İyileştirmek Amacıyla Yapılan Simülasyon ile İlgili Çalışmalar

Sistemleri anlamak, iyileştirme noktalarını tespit etmek ve iyileştirme fikirlerinin deneyebilmek, maliyet analizlerini yapabilmek için simülasyon yönteminin kullanılması gerekmektedir. Genel olarak çalışmaları incelediğimizde kesikli olay simülasyon metodunun acil servis sistemini anlamak için çok doğru bir yöntem olduğunu, kalabalığın ana sebebini keşfetmekte çok faydalı olduğunu, yapılan doktor, hemşire sayısındaki değişimlerin veya acil önem sıralama sisteminde yapılan değişikliklerin katkısı çok keskin bir şekilde ölçüldüğünü ifade etmişlerdir. İlgili makaleler aşağıda sunulmuştur.

Paul ve ark. (2012), acil servislerde kalabalığın sağlık hizmetlerinin etkinliğini azalttığını tespit etmişler ve bu problemi çözmek, kalabalığın sebeplerini incelemek için genel bir model geliştirmişler ve bu modeli de çalışmayı gerçekleştirdikleri hastaneye uygulamak istemişlerdir. Acil servisin işleyişin oldukça karmaşık olmasından dolayı kesikli olay simülasyon modeli geliştirmişler; böylece farklı çözümleri, senaryoları deneme şansını yakalamışlardır. Yoğun saatlerde yeterli doktorun olmaması, laboratuvar ve radyoloji test sonuçlarının yavaş çıkması ve gelen hastanın yatağa yatırılana kadar geçen vaktin fazla olmasını kalabalığın sebepleri olarak belirlemişlerdir. Yeterli doktorun olması durumunda kalabalığın %18 olarak azaldığını bulmuşlardır. Sonuç olarak simülasyon çalışmasının öncelikle kalabalığın ana sebeplerini keşfetmeye daha sonra da farklı çözümlerin nihai katkılarını görmeye çalışmışlar ve aynı zamanda rakamsal sonuçlar sayesinde simülasyon çalışmasının finansal anlamda fayda zarar analizine imkan sunduğunu belirtmişlerdir.

Kilmer ve ark. (1995), acil servislerin karmaşık ve dinamik yapısının, girdilerin, çıktıların ve eylemlerin birbiriyle içe içe ilişkili olmasının, kesikli olay simülasyon model yönteminin, bu servisleri incelemek için kullanılmasının bir nevi zorunluluk olduğunu belirtmişlerdir. 750 yataklı ayda 4200 hastaya bakan bir

hastane için gerçek sistemi tamamen benzeterek bir simülasyon modeli geliştirmişler ve doğrulamasını simülasyonun çıktılarıyla, gerçek sistemde yaptıkları gözlemleri karşılaştırarak yapmışlardır. Simülasyonun uzun hesaplama saatlerini hafifletmek ve senaryoları optimize edebilmek için meta model geliştirmişlerdir, böylece gerçek zamanlı çalışmalarda çok hızlı bir şekilde karar zamanlı sisteme müdahale edebileceklerini ifade etmişlerdir. Yapay sinir ağlarının tahmin etmede ki gücünden dolayı YSA'yı meta modelde kullanmışlardır. İki tane paralel yapay sinir ağları modeli geliştirmişler, bir model ile hasta kalış süresinin ortalamasını, diğer model ile de sapmasını tespit etmeye çalışmışlardır. Simülasyon modelinin çıktılarını, örneğin röntgen süresini, laboratuvar süresini yapay sinir ağlarına her bir nöronun ayrı ayrı olmak üzere girdi olarak kullanmışlardır. Yapay sinir ağlarının tahmini ile simülasyonun kendi çıktılarını karşılaştırdıklarında YSA'nın kullanıldığı meta modelin üstün olduğu gözlemlenmiştir. YSA ile geliştirilen modelin tahminleri kullanılarak, gerçek sistemde analiz ve optimizasyonu yapılabileceğini belirtmişlerdir.

Komashie ve ark. (2005), kesikli olay simülasyon modelini kullanarak, acil servisi incelemeye ve kalabalık problemin arkasındaki sebepleri görmeye çalışmışlardır. Anahtar performans göstergelerini değerlendirerek farklı senaryoların maliyet analizini yapmak istemişler, aynı zamanda yönetimin kaynak çoğalmasında veya süreçlerin değişiminde hasta akışının nasıl değiştiğini gözlemleyebilmesini sağlayabilmesine katkı sunmuşlardır. Simülasyon modelin doğrulamasını, gerçek sistemin bekleme zamanını ve bekleme sırasındaki sayıyı simülasyonla karşılaştırıp, acil servis yöneticisinin onayını alarak gerçekleştirmişlerdir. Hastanın toplam bekleme süresi en fazla 249 dakika en az ise 182 dakika olarak gerçekleşmiş olup, doktor ve hemşire sayısının ayarlanmasıyla en az bekleme süresinde 28% iyileşme olurken, toplam bekleme süresinde 9% iyileştirmeye sebep olduğunu gözlemlemişlerdir. Aynı zamanda bu çalışma yatak sayısının yeterli olmasının hasta akışını oldukça olumlu etkilediğini göstermiştir.

Connelly ve ark. (2004), kesikli olay simülasyon modelini acil servise uygulamış ve buna EDSIM adı vererek, potansiyel uygulamasını da yapmışlardır. Bu uygulamada acil önemine göre iki ayrı sıralama sistemi kullanılmıştır. Bu modele girdi olarak çalışanların sayısı ve diğer acil servis bilgileri girilmiş olup, tahmin edilen hizmet süreleri ile gerçekleşen hizmet süreleri karşılaştırılarak modelin doğrulanması sağlanmıştır. Acil önem derecesine göre yeni bir sıralama sistemi ile hızlı-izleme acil önem sıralama yaklaşımı karşılaştırması yapılmıştır. EDSIM hasta hizmet sürelerini gerçek değerlerine göre aşağı yukarı 10% yaklaşmıştır, önerilen yeni sistem acil önemi yüksek hastaların hizmet süresini kısaltırken diğer hastaların servis süresinin yükselmesine sebep olduğunu ifade etmişlerdir. İki ayrı yaklaşımda hasta hizmet sürelerinin oldukça farklı çıkmasından dolayı, daha farklı araştırmalar yapılması gerekliliğini belirtmişlerdir.

Brailsford (2014), bu çalışmada son zamanlarda kesikli olay simülasyonun artık geçersiz olduğu, aracı tabanlı simülasyonun artık geçerli olduğu söylemine karşı kesikli olay simülasyonun araç tabanlı simülasyonun sağladığı tüm yararları sağlayabileceğini ifade etmişlerdir. Bunun için de örnekler vermiş olup, bu tartışmanın şu an için cevabı olmayan akademik bir soru olduğunu belirtmişlerdir. Bu sorunun cevabının, kesikli olay sisteminin modelleyebildiği fakat araç bazlı simülasyonun modelleyemediği veya tam tersi bir durum olana kadar verilemeyeceğini, şu an için kesikli olay simülasyonun var olan tüm ihtiyacı araç bazlı simülasyon modeli kadar karşıladığını, birbirlerine üstünlükleri olmadığını ifade etmiştir.

Gül ve ark. (2012), Türkiye'nin doğu Anadolu bölgesinde bir hastanenin acil servis birimini kesikli olay simülasyon yöntemi ile modellemişler, çıkan sonuçlara göre iyileştirmeler yapmışlardır. İyileştirmek için hasta kalış süresini ve diğer kaynakların kullanım oranını arttırmayı kendilerine hedef seçmişler ve bunu başarmak için insan kaynak tahsisinde değişiklik yapmayı düşünmüşlerdir. Farklı senaryoları denedikten sonra, doktor ve hemşirelerin çalışma saatlerinde ve

sayılarında değişiklik yapmışlardır. Hemşire ve doktor sayısının akşam saatlerinde birer sayı fazla arttırıldığında hasta kalış süresinin 30% iyileştiği gözlemlenmiştir. Yılda 40.000 kişiye bakılan bu hastanede 5 karşılama görevlisi, 11 doktor ve 13 hemşire şeklinde hizmet yapılması durumunda bakılan hasta sayısı 12,5% artmıştır. Bu çalışmada aynı zamanda hasta gelişinin çok arttığı ve düştüğü senaryoları da çalışılmış ve literatürde benzer çalışmalarla karşılaştırılmış, ortalamanın üstünde bir iyileşme sağlandığı gözlemlenmiştir.

Gül ve ark. (2014), normal ve felaket durumları için acil servislere yönelik operasyonel, stratejik ve taktiksel karar vermede çok önemli olan simülasyon uygulamalarının kapsamlı bir incelemesini yapmışlardır. Ayrıca, literatürün aksine simülasyonun yaratıcılığa çok açık olduğunu göstermek istemişlerdir. Yaptıkları incelemede kesikli olay simülasyon yönteminin en çok Kanada, Amerika Birleşik Devletleri ve İngiltere’de kullanıldığını, genelde de seçilen konuların, hasta kalış süresi, kaynak kullanımı, tedavi göremeden dönen hasta sayısı ve finansal analiz olduğunu, ARENA ve Simul8’in diğer yazılımlar arasında en çok tercih edilen yazılımlar olduğunu belirtmişlerdir. Simülasyonun yöneylem metotları ve yönetim sistemleri ile beraber uygulanmasının çözümlerdeki başarıyı arttıracaklarını, acil servislerde maliyet kontrolü üzerine çok az çalışma olduğunu, verimlilik, hizmet kalitesi artırıcı ve yeniden mühendislik çalışmalarının, maliyet analizleri ile birlikte yapıldığında çok daha doğru ve açıklayıcı olacağını, veri toplarken yaratıcı yaklaşımların kullanılması gerektiğini, çünkü simülasyon çalışmalarında gerçeği tam olarak yansıtmak için veri toplama safhasının çok önemli olduğunu, ayrıca çalışmaların acil servis içine odaklandığını ama bölgedeki acil servisler arasındaki ilişkiye de odaklanması gerektiğini özellikle felaket durumlarında diğer acil servislerden hemşire veya doktor istemi olabileceğini ifade etmişlerdir.

Maidstone (2012), yöneylem metotları içerisinde simülasyonun bir çok sebepten dolayı çok önemli bir yöntem olduğunu ve en önemli üç simülasyon yönetiminin, kesikli olay simülasyonu, aracı bazlı simülasyon ve sistem

dinamikleri olduğunu ifade etmişlerdir. Kesikli olay simülasyon yöntemi gerçek sisteminde doğal kuyruklar olan sistemler için ve kesikli olay simülasyonu kendi yapısı stokastik olup, sistemi tam analiz edebilmek için defalarca çalıştırılması gerekmektedir ve sonuçları incelemek için istatistiksel metotlardan faydalanılması gerektiğini ve bu yöntemin modellenmesi ve doğrulanmasının sistem dinamikleri simülasyon yöntemine göre çok fazla zaman aldığını ifade etmişlerdir. Aracı bazlı simülasyon modelinde araçlar kendine ait davranışları vardır ve bu yüzden aktif olarak anılırlar, kesikli olay simülasyon modelinde ise sistemin tanımladığı şekilde hareket ederler ve bu yüzden pasif olarak anılırlar, aracı bazlı simülasyon yönteminde kuyruk düşüncesinin olmadığını ifade etmişlerdir. Üç modelinde farklı durumlarda faydaları veya kullanışsız olabileceğini belirtmişler ve problemin kendi yapısının metodu tanımlayacağını bunun için de sistem hakkında ve simülasyon modelleri hakkında detaylı bilgi sahibi olunması gerektiğini belirtmişlerdir.

Ahmed ve ark. (2009), Kuveyt'deki devlet hastanesinin acil servisinde olması gereken ideal doktor, hemşire ve karşılama görevlisi sayısını, en fazla sayıda hastaya hizmet vererek ve aynı zamanda hasta kalış süresini en aza indirgeyerek belirli bir bütçe dahilinde optimize etmeye çalışmışlardır. Bunun için simülasyonla beraber bir optimizasyon modeli kullanılmıştır. Bu model sayesinde hizmet edilen hasta sayısı 28% artmış ve hasta kalış süresi aynı kaynaklar kullanılarak 40% azaltılmıştır. Bu iyileştirmenin sürekliliğini sağlamak için karar destek modeli geliştirilmiş, böylece hastanedeki karar vericiler değişen duruma göre çalışanların vardiya dağılımlarını ayarlayabileceğini ve böylece ideal kaynak tahsisinin yapılabileceğini ifade etmişlerdir. Simülasyon yazılımı girdi bilgilerini Excel'den almıştır.

Baxt ve ark. (2002), acil servislere ikinci olarak en sık göğüs ağrısı şikayeti ile geldiğinden yola çıkmışlardır. Bu sancı çok önemsiz olabileceği gibi, öldürücü bir kalp rahatsızlığının da habercisi olmaktadır. Bu sancının kalp rahatsızlığından olup olmadığını anlamak için 2204 yetişkin üzerinden veriler

alınmıştır. Jack-knife varyans yöntemi ile ağlar eğitilmiş ve test edilmiştir. Hastaların geçmişine ait 40 değişken için veriler alınmış ve öznitelikler modele verilmiştir. % 95 güvenlik aralığında, %88,1 seviyesinde teşhiste başarılı sonuçlar alınmıştır. Bu sonuçlar bize yapay sinir ağlarının, acil servise gelen hastalarda teşhis için de kullanılabileceğini göstermektedir.

Asplin ve ark. (2003), Amerika’da acil servislerde gittikçe artan kalabalığın bu hizmetleri verirken dikkat kaybolması, geç müdahale ve verimsiz kaynak kullanımına neden olduğunu ifade etmişler ve bu konuya ışık tutmak bundan sonraki çalışmalara yardımcı olmak amacıyla, girdi-süreç-çıkış içerikli kavramsal bir model geliştirmişlerdir ve bu modeli uzmanlarla tartışarak iyileştirmişlerdir. Performans ölçümü için bu servislerde hasta kalış süresini düşürmüşler ve bu sürenin düşürülmesi için de yeni fikirler geliştirmişlerdir. Örneğin, farklı bir acil önceliği sıralama sisteminin kalış süresini iyileştirebileceğini ifade etmişlerdir, fakat bu kalabalığa sebep verebilecek, tatil günleri, mevsimler gibi özniteliklerden bahsetmemişlerdir. Bu çalışma acil servisin işleyişini anlamak açısından oldukça faydalı bir çalışma olmuştur.

Çizelge 2.1. Önceki Çalışmaların Kıyaslanması

Yazar (Yıl)	Kullanılan/ Yaklaşım	Kullanılan öznitelik yapısı	Tahmin için Hedeflenen süre	Veri süresi/kaynağı
McCarthy ve ark. (2008)	Poisson olasılık dağılımı	Zamansal şartlar ve hava durumu	Saatlik tahmin	8760 saat
Jones ve ark. (2008)	ARIMA, YSA, Üssel yumuşama tekniği	Zamansal veriler, haftalık ve mevsimsel döngüler	Günlük Tahmin	3 farklı hastaneden 27 aylık günlük veri,
Abraham ve ark. (2009)	Mevsimsel ARIMA	Zamansal veriler	Günlük Tahmin	3 yıllık günlük hasta geliş bilgisi
Sun ve ark. (2009)	ARIMA	Hava kirliliği indeksi, zamansal veriler, Takvimsel veriler	Günlük Tahmin	3 yıllık indeks,hsata geliş sıklığı, resmi tatiller vb.
Boyle ve ark. (2010)	ARIMA, Çoklu regresyon ve Üssel düzgünleştirme	Zamansal değişkenler, Takvimsel veriler	Aylık, günlük,4 saatlik,1 saatlik	İki hastaneden 5 yıllık kayıt alınmıştır,
Bergs ve ark. (2013)	Üssel yumuşatma	Zamansal veri	Aylık tahmin	4 ayrı Acil servisten 6 yıllık aylık veri
Xu ve ark. (2013)	YSA, çoklu doğrusal regresyon modeli, doğrusal olmayan en küçük kare sistemi ile regresyon	Zamana bağlı değişkenler ve hava durumu parametreleri	Günlük tahmin	12 aylık hasta geliş bilgisi
Gül ve ark. (2015)	YSA	Hasta yaşı, cinsiyeti, hastaneye geliş şekli, acil serviste uygulanan tıbbi testler ve muayene sonuçları	Hasta kalış süresi tahmini	1500 hasta kaydından veri alınmıştır
Gholipour ve ark. (2015)	YSA	Klinik ve biyokimyasal veriler	Hasta kalış süresi	184 adet travma geçiren hasta

Çizelge 2.2'in devamı

Golmohom madi (2016)	YSA, Lojistik regresyon	Yaş, evlilik durumu, hastaneye geliş şekli, radyoloji muayenesi	Yatak talebi ve süresi	6 aylık, 11.500 hasta kaydı
Lucini ve ark.(2017)	Karar ağacı, rastgele orman, Lojistik regresyon, Adaboost, son derece rastgele ağaç, destek vektör makinesi, nu-destek vektör makinesi, Naif Bayes sınıflandırma algoritması	Hastanın hemen karşılama bölgesinde alınan bilgiler	Yatak talebi ve süresi	16,743 hasta kaydı
Silva ve ark. (2017)	ARIMA	Zamana bağlı değişkenler	Haftalık hasta geliş tahmini	2 yıla ait hasta Kaydı kullanmışlar
Hong ve ark. (2018)	Derin öğrenme, Gradyan artırımı ve lojistik regresyon	Acil önemine göre sıralama bilgileri	Günlük hasta geliş tahmini	560,486 hasta kaydı
Parker ve ark (2018)	Lojistik regresyon	Hastanın yaşı, ırkı, posta kodu ve ateş durumu ve zamansal değişkenler	Hastanın kaydı yapıldıktan sonraki beklenen kalış süresi	10 yıllık hasta verisi
Hertzum (2018)	ARIMA	Zamansal veriler	Saatlik hasta geliş sıklığı	2 yıllık hastane verileri
Graham ve ark. (2018)	Lojistik regresyon, Gradyan artırımı, Karar ağacı gözetimli algoritmaları	Zamansal özellikler ve acilliğine göre sıralama bilgileri	Saatlik tamim	İki hastaneden toplam 120.600 kayıt

3. MATERYAL VE METOT

3.1. Materyal

Bu çalışmada kullanılan veriler Ceyhan Özel Çınar Hastanesinden alınmıştır. Ceyhan ilçesi Adana'nın doğusunda, Adana'ya 47 km uzaklıkta olup, merkez nüfusu 160,470 kişi ile Adana'nın çevresindeki ilçelerin en kalabalık olanıdır. Ceyhan'daki tek özel hastane olması sebebiyle de özellikle acil servis biriminde hasta tedavi sürelerinin uzun olduğu bir hastanedir. Hastane kayıtları, kullanılan yazılım sayesinde detaylı olarak tutulabilmektedir. Hastalar acil servise ambulansla yada kendi imkanlarıyla gelmektedir. Acil servis biriminde toplam 3 doktor, 7 yatak 10 hemşire bulunmaktadır. Acil servis, laboratuvara, MR ve röntgen alanlarına çok yakın mesafeye yerleştirilmiştir. Ayrı girişi olan acil serviste acil önemine göre sıralama sistemi de uygulanmakta ve yılda ortalama yaklaşık 35.000 hasta tedavi görmektedir. Hastanedeki acil servis birimindeki kalabalık problemi, hasta kayıtlarının düzgün olması ve hastane yönetimin çalışmamıza yardımcı tutumu vaka çalışmasını bu hastanede yapmamız konusunda teşvik edici olmuştur.

Çalışmada geliştirilen modellere girdi olacak verilerin hazırlanması için öncelikle hangi verilerin gerekli olduğuna dair bir çalışma yapılmıştır. Bu çalışma iki yönlü yapılmıştır. İlk olarak, acil servis biriminde gözlem yapılmıştır. Yapılan gözlemlerle, acil servis çalışanları ve hastane yönetiminin de katılımıyla hastaların izlediği rotalar, bu rotaları kullanan hasta yüzdesi, hastalara uygulanan işlemler ve işlem süreleri tespit edildi. Bu bilgiler sistemin simülasyonla modellenmesin temel verilerini oluşturdu. İkinci olarak da, geliştirilen simülasyon modelinin en önemli girdisi olan hasta geliş sıklıklarının öngörülebilmesi için gerekli öznitelikler hem hastane çalışanlarının görüşleri alınarak hem de literatür taraması yapılarak belirlenmiştir. Literatürde, hava durumu, resmi tatil gibi durumların hasta geliş sıklığını etkilediği bilgisinden ve hastane çalışanlarından alınan bilgilerden

faýdalanılarak zamansal veriler ve hava durumunun verilerinin derlenmesine karar verilmiştir. Hastaneden alınan 5 yıllık hasta kaydı, hava durumuna ait veriler ve takvimsel veriler Phyton yazılımı kullanılarak kullanılabilir hale getirilmiştir. Bu yazılım sayesinde veriler saatlik ve günlük olarak sınıflandırılabilmiş ve yapay zeka algoritmalarına girdi olarak hazırlanmışlardır. Yalnız, hava durumunu ilgilendiren veriler en az 3 saatlik farkla bulunabildiği için son üç saatin nem, sıcaklık, yağmur gibi değerleri aynı kabul edilmiştir. Tüm bu veri düzenlenmesi işlemlerinde açık kaynak kodlu Phyton yazılımı kullanılmıştır.

Yazılım teknolojisinde lisanslı yazılımlar, açık kaynak kodlu yazılımlar ve bulut hizmetleri bulunmaktadır. Lisanslı yazılımlarda programın kaynak kodu, sadece programı satın alan kişilere verilmekte, güncellenme işlemi de ücretli olarak gerçekleştirilmektedir. Bulut hizmetleri, aboneliği olan veya kullanma süresi hakkını alan uygulamacılara açılan yazılım hizmetleridir. Ücretsiz yazılım hizmetleri verenler ise açık kaynak kodlu yazılımlardır. Açık kaynak kodlu yazılımda, kod tedarikçisi yazılımcının amacını sorgulamadan, yazılımdan hak talep etmeden, koda sınırsız erişim imkanını vermektedirler. Programın bakımından, güncellemesinden veya destek programlardan da ücret talep edilmemektedir. Günümüzde, Google, Amazon gibi büyük kuruluşlar açık kodlu kaynaklara önem vermekte ve kendi yazılımlarını dahi açık kodlu kaynak haline getirmektedirler (Gürsaka, 2017).


Python yazılımı açık kodlu kaynak kullanımına bir örnektir ve bu çalışmada da Phyton yazılımı kullanılmıştır. Python nesne önemli bir program dili olup, 1980 yılları sonlarında ortaya çıkarılmış daha sonra topluluk tarafından geliştirilmiş bir programlama dilidir. Makine kodlarına yazılmamış, yorumlayıcı ile çalışmaktadır. Bu yorumlayıcının yüklendiği bilgisayarlarda çalışabilir. Bu da rahatlıkla test edilmesine ve hataların düzeltilmesine imkan vermektedir. Bu sebepten dolayı, programcılar programın kendisinden çok programın mantığına odaklanabilmektedirler. MATLAB ile çok fazla benzerlikleri bulunmaktadır.

Phyton, kendi sitesinden indirilerek ücretsiz olarak ulaşılabilen bir programdır (Kiusalaaas, 2005).

Python'ın, diğer geleneksel yazılımlara göre kodları çok daha anlaşılır olup, C++ veya Java ile yazacağınız kodlar sırasıyla 1/3 ve 1/5 gibi oranda Phytonda yazılabilmektedir. Python programlarınızı daha hızlı, sisteminize entegre ve etkin bir şekilde yapılmasına olanak sağlayan bir programlama dilidir. Büyük bilgisayar platformların hepsinde Mac, Windows, Lin  x gibi   alıştırılabilmektedir. Aynı zamanda di  er yazılımlarda entegre   alışabilir, onların k  t  phanesini kullanabilir. Python programlama dilinin de   nceden olu  turulmu  , ta  ınabilir   ok kullanılan kod par  acıklarına ait dosyaları bir b  t  n halinde saklayan k  t  phaneleri bulunmaktadır.   zellikle de veri bilimi ile ilgili olarak NumPy, Pandas, Matplotlib, SciPy k  t  phaneleri sıralanabilir. (Lutz ve ark, 2004). Bu   alı  mada Phytון yazılımında makine    renme algoritmaları ve yapay sinir a  ları modelleri olu  turulmu   ve daha sonrada hedef   ıktının girdi olarak kullanılaca  ı sim  lasyon modeli geli  tirilmi  tir. Bu   alı  mada sim  lasyon yazılımında, Arena kullanılmı  tır.

Sim  lasyon modellemesinde en sık kullanılan yazılımlardan biri olan Arena: Rockwell-otomasyon tarafından geli  tirilmi   pop  ler, geni   ama  lı bir sim  lasyon programıdır. Arena programı, sim  lasyonun ba  arılı olmasını sa  layacak, girdi ve   ıktı analizi, animasyon gibi fonksiyonları ayrıntılı ve kapsamlı bir   ekilde i  ermektedir. Arena'da, mod  ller fonksiyonel olarak   ablonla da hazırlanmı  tır, bu kısa yollarla da ula  mamız m  mk  n olan mod  lleri birbirine ba  layarak, bankadaki m   teri, hastanedeki hasta gibi ki  ilerin veya malzeme gibi varlıkların akı  ı tasarlanmaktadır. Bu mod  llere de (hasta kalı   s  resi, tedavi s  resi, bir sonraki i  lem adı vb.), bilgilerin detaylı giri  leri yapılarak, model programı olu  turulmaktadır. Arena ile ki  iye   zel mod  ller geli  tirilerek, onları da yeni bir   ablonda saklamak da m  mk  nd  r. En g  zel imkanlarından biri de Arena'nın ger  ek sistemlerle aktif olarak   alışabilmesi ve sistemle dinamik olarak interaktif ileti  ime ge  ebilmesidir (Law, 2007). Acil servis i  in geli  tirdi  imiz

simülasyon programının karar modülleri ve hasta akışını tanımlayan bağlantılar Şekil 3.1’de sunulmuştur.



Şekil 3.1. Arena Yazılımında Ara Yüz

3.2. Metot

Bu çalışmada, acil servislerde kaynak planlanması için bir simülasyon modeli geliştirilmiştir. Bu modeli geliştirmek ve literatürdeki boşlukların giderilmesi amacıyla bu çalışma 4 aşamada gerçekleştirilmiştir.

İlk olarak, tüm acil servis sistem işleyişi, kaynak tahsisi, acil önemine göre sıralama sistemi, diğer birimlerle ilişkisi, personel sayısı ve niteliği, hastaların hastaneye geliş şekilleri ve gelen hastaların acil servis içinde izlediği yol ve bu işlemlerde geçen süreler detaylı olarak gözlemlenmiş, incelenmiş ve acil servisin akış şeması oluşturulmuştur. Acil servislerdeki en önemli problemin önceki çalışmalarda belirtildiği gibi, aşırı kalabalık ve bundan dolayı yatması gereken hastanın hemen yataklı tedaviye ulaştırılamaması olduğu gözlemlenmiş ve yatak sayısı optimize edilmeye çalışılmıştır.

İkinci aşamada, verilerin derlenmesi ve toplanması yapılmıştır. Simülasyon modeli için gerekli tüm veriler hastane kayıtlarından, personelinden ve

hastane gözlemlerinden elde edilmiştir. Hava durumu ile ilgili veriler bölgesel metroloji istasyonundan toplanmıştır. Bu veriler daha sonra Phyton yazılımı ile kullanılabilir hale getirilmiştir. Örneğin, hava durumu ile ilgili bilgiler üçer saatlik olarak alınıp, üç saatlik dilimdeki her bir saate aynı hava durumu bilgisi girilmiştir. Ayrıca takvimsel veriler yine Phyton yazılımı yardımıyla süzölmüş resmi veya dini tatil günleri, haftanın günleri, hafta sonu tatilleri belirlenmiş ve tüm bu veriler istenilen zaman biriminde birleştirilmiştir. Yine Phyton yazılımı ile detaylı bir öznitelik kümesi oluşturulduktan sonra da kapsamlı öznitelik seçim metoduyla ideal öznitelik kümesi oluşturulmuştur.

Yatak sayısını optimize etmekte kullanılan simölasyon modelinin iyi sonuç vermesi için en önemli girdilerinden biri olan hasta geliş sıklığının iyi tahmin edilebilmesi son derece önemlidir. Bu nedenle literatürdeki tahmin modelleri incelenerek, tahmin konusunda en başarılı metotların makine öğrenme algoritmaları olduđu tespit edilmiştir. Bunun içinde diğerk çalışmalarda başarılı olan gradyan artırım gibi makine öğrenme metotları ya da pek kullanılmamış olan K-en yakın komşu modeli gibi 9 makine algoritması belirlenmiştir. Ayrıca daha önceki çalışmalarda kullanılmamış olan yineleyen sinir ağıları metodu yapay sinir ağıları metotları içinden seçilmiş ve yineleyen sinir ağıları metodunun bir türü olan uzun kısa hafıza metodu (LSTM) da bu çalışmada kullanılmıştır. Tüm bu algoritmaların mimari yapısı da bu çalışmada belirlenmiş ve modeller geliştirilmiştir. Böylece çalışmanın ana hedeflerinden biri olan hasta geliş sıklığı tahminleri bu metotlarla yapılmıştır.

Dördüncü olarak da acil servis sistemini daha rahat anlamamızı sağlayacak ve yatak sayısını eniyilemede kullanacağımız simölasyon modeli geliştirilmiştir. Tüm simölasyon çalışmalarında yapıldığı gibi, simölasyon modelinin doğrulanması ve onaylanması da gerçekleştirilmiştir. Simölasyon modelinin gerçek sistem ile benzediğinin doğrulanması ve onaylanması yapıldıktan sonra farklı yatak sayısında

sistemin çıktılarının nasıl değiştiği incelenmiş ve ideal yatak sayısı sorusuna cevap bulunmuştur.

3.2.1. Yapay Zeka

Yapay zeka, insan gibi düşünebilmek değil ama insan zekasının başarabildiği algılama, sürekli öğrenme, öğrendikleri ile sonuca varma, görme, karara ulaşabilme gibi işlemleri bilgisayar yardımıyla yapabilmek olarak tanımlanabilir. Yapay zeka (YZ), beynimizdeki nöronların yaptığı işlevi, yapay nöronlarla bir iletişim ağı oluşturarak çıkarım yapan, tahmin yapabilen, sorun çözebilen, teşhis koyabilen bir yapay işletim sistemidir. Bu yönelim, insanın tüm evreni okuma ve yaşama çabasında kendisi ile yürüyecek bir dost gibi de düşünülebilir (Alpaydın, 2013).

1940'lı yıllarda McCulloch ve Pitts tarafından yapay zeka ile ilgili ilk çalışmalar yapılmış ve 1943 yılında bu konuyla ilgili ilk matematiksel modeli geliştirilmiştir. 1949 yılında Hebb tarafından öğrenme için matematiksel bir yaklaşım, 1951'de Minsky tarafından sinapsların ayarlanmasıyla belirli bir işi başarabilecek 40 nöronlu bir öğrenme sistemi ve 1957 'de Rosenblatt ve McCulloch-Pitts tarafından öğrenme ve hatırlama geliştirilmiştir. 1960'larda Grossberg, kendi kendine öğrenebilen bir YSA yapıları üzerine çalışmalar yapmış, 1965'de Zadeh tarafından önerilen bulanık mantık teorisi ise YZ'yi yeni bir bakış açısı getirmiştir. Yalnız, 1969 yılında Minsky ve Papert, Perseptonlar adlı bir kitapta yazarlar ve bu kitapta tek katlı YSA'ların sıradan problemleri bile çözemeyeceğini öne sürerek çok katlı YSA'larının tek katlılardan farklı sonuç vermediğini göstererek bu konuda yapılan çalışmaların durmasına sebep olmuşlardır. Buna rağmen az da olsa bazı çalışmalar devam etmiş, 1975'de Holland, canlılarda doğal gelişim prensibine dayanan genetik algoritmayı önermiş ve 1976'da Sejnowski Boltzman Makinasını geliştirmiş ve buna geriyayılım (BP) algoritmasını uygulamıştır, 1978'de de Sutton ve Barto ise takviyeli öğrenme

modelini geliřtirmişlerdir. YZ ile ilgili yapılan çalışmalar 1970’den sonra azalmış ve konuya ilgi kaybolmuşken, Minsk ve Papert’in kitaplarında ki fikirler yine bir başka kitap PDP ile yürütölmüştür. McClelland ve Rumelhart’ın 1986 yılında yazdıkları bu kitapta verdikleri uygulamalar, yapılacak olan bir çok çalışmaya yön vermiştir. 1987 yılında ilk uluslararası yapay zeka konferansı yapılmış ve bu alanda çalışmalar çok fazla yaygınlaşmıştır. Birçok disiplinden, nörologlar, biyologlar, fizyologlar, mühendisler, matematikçiler ve fizikçiler, bilim insanları ekip çalışmaları yaparak yapay zekayı geliřtirmişlerdir. 1997 yılında IBM’in geliřtirdiğı bir bilgisayar olan Deep Blue, Rus satranç ustası Garry Kasparov’u mağlup eder ve yapay zeka çalışmaları daha da hızlanır (Pirim, 2006).

Yapay zekanın geliřtirilmesindeki amaçlar, insanların zekaları ve akılları ile gerçekleřtirdikleri, bilgilenme, anlama, yorumlama ve çıkarım yapmada uyguladıkları zihinsel aktiviteleri arařtırmak; bunları sağılayan zihinsel teknikleri algoritma haline getirmek ve bilgisayarlarla bunu uygulamak; insan/bilgisayar ara birimleri geliřtirmek; belirli konularda uzman sistemler geliřtirmek; bilgi toplumunun alt yapısını oluřturmak; iş yardımcıları ve robotlar geliřtirmek ve arařtırma yardımcıları geliřtirerek bilimsel gelişmeyi hızlandırmak olarak sıralanabilir.

Yapay zeka çalışmaları başlangıçta insan gibi düşünen ve davranan bir yapıyı tasarlamak da olsa, zamanla bunun řu an için mümkün olmadığı anlaşılarak, akla ve mantığa uygun analizler yapan sistemler tasarlanmaya odaklanılmıştır. YZ insanın düşünme sistemini taklit etme amacıyla başlamış, artık insan vücudundaki diğerk mekanizmalardan veya farklı canlıların çalışmasından esinlenerek yeni teknikler bulunmuş ve bulunmaya devam edilmektedir. YZ teknikleri bilgi tabanlı uzman sistem yaklaşımı, yapay sinir ağıları yaklaşımı, makine öğrenme algoritmaları, bulanık mantık yaklaşımı, sezgisel algoritmalar (genetik algoritma, Karınca algoritması, Tabu arama, yumuşak programlama), olarak sıralanabilir.

3.2.1.1. Uzman Sistemler

Uzman sistemler, özel bir alanda ve sadece o alanda başarılı olmak ve insanın amaçlarına hizmet edebilmek için tasarlanmış, eğitilmiş ve bilgilendirilmiş sistemlerdir. Bir konudaki uzman insanın davranışlarını ve düşünce yaklaşımlarını örnek alarak o insan gibi veya ondan daha iyi çözümler getirmesi beklenen sistemlerdir. Bu sistemlerin daha iyi çözüm getirmesi beklenebilir, çünkü bu konuda birçok uzmanın bilgisine sahiptirler. Bu yüzden de uzman sistem adını almışlardır. Bu sistemler uzman insanların işini çok kolaylaştırabilmektedir. İlk uzman sistem 1976 yılında MYCIN adıyla, bakteriyolojik ve menenjik hastalıkların tedavisi için geliştirilmiş, hastanın geçmiş bilgileri, hastalıkla ilgili belirtileri ve laboratuvar bilgileri derlenerek, hastaya teşhis konması ve reçete yazılımı sağlanmıştır. Daha sonraki süreçte uzman sistemler kabuklarından yararlanarak çok daha hızlı uzman sistemleri geliştirilmiştir. Uzman sistemlerin bir diğer önemli özelliği de hafızalarının güncel olması, kuralları ve prensipleri çalışıkça öğrenmesidir. Birçok uzman sistemin temel özelliği, kurumaların mevcut işletim sistemleri ile entegre olabilmesidir. Bir diğer özellikleri de ihtiyaç durumunda diğer yazılımlarla bağlantı kurabilmeleri ve ortak çalışabilmeleridir (Liebowitz, 1995).

3.2.1.2. Bulanık Mantık

Bulanık mantık kavramı 1965 yılında Prof. Dr. Lotfi Asker Zadeh tarafından ortaya atılmıştır. Matematiksel düzende olaylara siyah beyaz, sıfır veya bir olarak bakabiliriz, ama gerçek hayatta grinin tonları bulunmaktadır ve bilim bunları da açıklamalıdır. Bu noktada bulanık mantık devreye girmekte ve az, çok, biraz gibi nitelemelerle çalışmaktadır. Hiçbir şeyin kesin doğru ve kesin yanlış olmadığı durumlarda bu yaklaşımın olumluluğu çok daha fazla ortaya çıkmaktadır. Bulanık küme teorisi bu kavramı daha iyi açıklayabilmektedir. Misal olarak, iyi veya çirkin gibi belirtilecek ifadelerde, bu hem kişiden kişiye değişmekte hem de

matematiksel olarak da rahatça ifade edilememektedir. Bu ifadelere karşılık olarak bir veya sıfır denemese de yine de kendi aitlik fonksiyonu ile sıfır ile bir arasında bir değer verilerek ifade edilebilir. Bu şekilde matematiksel olarak modellenmesi zor olan sistemlerde, bulanık mantık kesin olmayan esnek yaklaşımlar kullanarak sistemlerin yönetimini sağlayabilir (Bezdek, 2014). Bulanık mantık ile her türlü sistem modellenebilmekte ve diğer yapay zeka teknikleri ile beraber çalıştırıldığında çok daha iyi sonuçlar alınmaktadır. İnsanın zihinsel aktivitelerine daha fazla yakın olup, matematiksel bir model olmaksızın basitçe programlanabilmesi ve daha az maliyetli olması olumlu tarafı iken kuralların nasıl olacağının uzmana bağlı olması, aitlik fonksiyonlarının deneme yanılma ile bulunması programın fazla uzun zamanda sonuçlandırması olumsuz yönleri olmaktadır. Günümüzde de bulanık mantıkla çalışan ev aletleri, arabaların çeşitli kısımları ve elektronik cihazlar üretilmektedir (Sağıroğlu ve ark, 2003).

3.2.1.3. Genetik Algoritma

Rastgele çalışma algoritmalarının bir türü olup, canlıların evrimleşme prensibine dayanmakta olup, Holland tarafından ilk olarak 1970 yılında geliştirilmiştir ve genellikle klasik yöntemlerle çözülmesi zor olan problemlerde kullanılır (İşçi ve ark,2003). Olası çözümlerin kodlandığı bir çözüm grubu oluşturulur. Her kromozomun ne kadar iyi olduğu bulunur (Yigit, 2011). Çözümlerin ne kadar iyi olduğunu bulmak için uygunluk fonksiyonu çalıştırılır ki bu fonksiyon algoritmanın beynini oluşturur. Genetik algoritmanın başarısı genellikle bu fonksiyonun başarısına bağlıdır ve bu fonksiyonların seçimi probleme, ilgili verinin yapısına bağlıdır. Bu çözümlerden yeni çözümler seçme metodlarından biri kullanılarak üretilir ve eski çözümlerin bir kısmı veya tamamı ortadan kaldırılır (Haldurai ve ark, 2016).

3.2.1.4. Karınca Algoritması

1991 yılında Dorigo ve arkadaşları tarafından geliştirilen bu algoritma eniyileme problemlerinde kullanılmaktadır. Gerçek karıncaların feromon kullanarak en kısa yolu bulmaları tekniği örnek alınarak geliştirilmiş bir algoritmadır. Karıncaların geçtiği yollara feromon bırakmaktadır ve karıncaların yolu kıaldıkça feromon bırakmaları artmaktadır. Bu algorithmada boş bir çözümle başlar ve tam bir çözüme ulaşana kadar iterasyon devam eder. Değer fonksiyonuna göre sayısal bir değer hesaplanır ve buna göre de yapay feromon miktarı hesaplanır. Buna göre ideal çözüme doğru gidilir (Rajendran, 2004).

3.2.1.5. Tabu Algoritması

Tabu arama algoritmasının bölgesel en iyi olan çözümü küresel en iyi kabul etmemek için, ölçme fonksiyonu tarafından her iterasyonda en yüksek değere sahip hareketin bir sonraki çözümü oluşturmak amacıyla seçilmesine dayanmaktadır. Tabu arama algoritması her ne kadar istenmeyen noktaların işaretlenmesi olarak açıklanmış olsa da daha cazip noktaların işaretlenmesi olarak ta kullanılır. Metotları, en iyi olma ihtimali, optimuma en yakın çözümleri belirlemeye ve daha sonra yerel arama için bu kutucuklar içerisinde başlangıç noktası seçmeye çalışır (Cura, 2008).

Tabu algoritması, eniyileme problemlerinin bazıları için geliştirilmiş sezgisel bir yöntemdir, ama, sürekli eniyileme problemlerine katkıları sınırlıdır (Hedar,2004).

3.2.1.6. Yumuşak Programlama

Uzman sistemler, bulanık mantık, yapay sinir ağları ve genetik algoritma uygulamalarda tek başlarına kullanılabildikleri gibi birçok problemin çözümünde, o problemin yapısına göre algoritmaların üstünlükleri dikkate alınarak çözüm

metotlarında birlikte kullanılırlar. Bu yaklaşıma yumuşak programlama adı verilir (Pirim, 2006).

3.2.1.7. Yapay Sinir Ağları

YZ biliminin tekniklerinden biri olan yapay sinir ağları araştırmacılar için en fazla ilgi çeken araştırma konusu olmuştur. YSA bilgisayarların öğrenmesine yönelik çalışmaları içerir. YSA'ları insanın öğrenme özelliğini taklit eden, biyolojik sinir sisteminden esinlenilmiş bir yaklaşımdır. Biyolojik sinir sistemlerinde nöron, dendrit, hücre gövdesi, aksonlar ve sinapslar bulunmaktadır. Nöronlar vasıtasıyla bilgi alma, işleme ve gönderme eylemi yapabiliriz. Nöronlar bilgi alma işlemini gövdeye giren sinyal alıcılar, dendritler sayesinde yapar ve işleme görevinden sonra aksonlar ile bu bilgiyi diğer kısımlara aktarırlar. Sinir sistemimizin temel birimi olan sinir hücresi nöronlar arasında iletişimin gerçekleştiği bölgelere sinaps denmektedir. Her sinir hücresinin aksonu bir diğer sinir hücresinin dendritine bir bağlantı göbeği olan sinapslarla bağlanmıştır. Sinapsların bazıları elektriksel, bazıları da kimyasal yollarla iletişimi gerçekleştirebilirler, elektriksel olanlarda iletişim çift yönlü iken kimyasallarda tek yönlü olmaktadır. Biyolojik bu sistemin bilgisayarda da karşılığı oluşturulmuştur. Biyolojik nöronların karşılığı olarak yapay nöronlar geliştirilmiş, bilgi girişi toplama fonksiyonu ile olur, biyolojik sistemde bunun karşılığı dendritlerdir; bilgi dağıtımı da aksonlarla olur, bu aksonların karşılığı da yapay nöron çıkışlarıdır. YSA' da bilgi taşınırken bu bilgi her bağlantıdaki ağırlık değerlerinde saklı ve ağa yayılmış durumdadır. Ağırlıkların tam karşılığı da insan sinir sisteminde sinapslardır (Sağıroğlu ve ark, 2003).

Yapay sinir ağlarının en alt birimi yapay nöronlardır. Bilgi girişi, bilgi çıkışı, toplama fonksiyonu, aktivasyon fonksiyonu ve ağırlıklardan oluşur. Bir katmanda p kadar ağırlığı olan nöronlar vardır. Tüm girdi bilgileri ağırlıkları ile çarpılır ve doğrusal olarak toplanarak aktivasyon potansiyelini oluşturur. Tüm bu

bilgi herhangi bir aktivasyon fonksiyonundan geçirilerek normalleştirilir ve genelde ya sıfır ile bir arasına ya da eksi bir ile bir arasında bir gerçek sayıya dönüştürülür. Doğrusal veya doğrusal olmayan aktivasyon fonksiyonları karmaşık problemleri çözmemize yardımcı olmuştur (Öztemel, 2003).

Doğrusal fonksiyon (ADALINE), basmak fonksiyonu, kutuplamalı basamak fonksiyonu, parçalı doğrusal fonksiyon, Sigmoid, tanjant hiperbolik, Re LU, Leaky Re LU, Exponential Linear Unit Fonksiyonu gibi aktivasyon fonksiyonları bulunmaktadır.

Sigmoid fonksiyonu en çok kullanılanlardan biridir, değerler en çok 0,2 ile 0,8 arasında değer almak üzere 0 ile 1 arasında dağılmışlardır. Exp() kullanıldığı için hızlı değildir. Tanh fonksiyonu sigmoidle benzerlik taşır, farkı ise 0 ile 1 arasına değil de değerleri eksi bir ile bir arasına dağıtır ve sıfır değer odaklıdır. ReLU Fonksiyonu sıfır odaklı değildir ve aldığı negatif değerleri sıfıra eşitler, aldığı değer pozitif ise olduğu gibi alır, diğer fonksiyonlara göre biyolojik nörona en çok benzeyen fonksiyondur. Leaky ReLU Fonksiyonu ise ReLU fonksiyonun tüm özelliklerini içermesine rağmen aldığı negatif değerleri çok küçük negatif değerlere atar ve hesaplaması çok daha hızlıdır. Exponential Linear Unit Fonksiyonu, ReLU fonksiyonun tüm özelliklerini içerir, yalnız exp() kullandığı için daha yavaştır (Sağıroğlu ve ark, 2003).

Yapay sinir ağları başlangıçta tek katmanlı bir nöron sistemi olarak başlamışlardır ve bu yaklaşımla doğrusal olmayan problemleri çözememişlerdir. Daha sonra çok katmanlı YSA ile doğrusal olmayan problemlerde çözülebilmıştır. Çok katmanlı yapay sinir ağlarında birincisi girdi katmanı, ikincisi ara katman ve üçüncüsü çıktı katmanı olarak en az üç katman olmaktadır. Yapay sinir ağlarını birbirine bağlayan bağlantılara ağırlık değerleri verilir. Değişik toplama ve aktivasyon fonksiyonları ile bu ağırlık değerlerinden bir çıktı elde edilir ve bir sonraki katmandaki nöronlara iletilir. Buna bilgi işleme denir. Ağın doğru çıktıları üretebilmesi için ağırlıkların doğru atanması gerekmektedir. Doğru ağırlıkların

atanması işlemine ağı eğitilmesi denir. Rasgele atanan bu değerler, daha sonra eğitim sırasında her döngü de ağı öğrenme kuralına göre ağırlıklar ayarlanır. Daha sonra bu döngü daha iyi sonuca ulaşılamayana kadar devam ettirilir ve ideal ağırlıklar bulunur. Bu sağlandıktan sonra eğer test aşamasında da başarılı sonuçlar alınırsa bu ağı eğitilmiş olur. Öğrenme kuralları ağırlıkların belirlenmesini sağladığından ağı başarılı olması için çok önemlidir (Alpaydın, 2013).


Öğrenme kuralları araştırmacılar tarafından çözmek istedikleri problemlere yönelik geliştirilmiştir. Öğrenme kuralları 4 ana öğrenme kuralından esinlenerek geliştirilmiş olup, bunlar Kohonen, Hebb, Delta ve Hopfield öğrenme kurallarıdır. Hebb kuralını, her iki nöronda aktif ise ve birbirlerinden giriş alıyorsa aralarındaki ağırlıklar güçlendirilmesi olarak tanımlamıştır (Kempster ve ark, 2009). Hopfield kuralında ise her iki nöron birbirinden bilgi alırken, her ikisi de aktif ise veya her ikisi de pasif ise aralarındaki ağırlık değeri güçlendirilir. Delta kuralı ise en sık kullanılanlardan biri olup, ağırlıklar sürekli azaltılıp veya çoğaltılabilmektedir. Çıktı değeri ile istenilen değer arasındaki farkın karesini en aza indirmeye çalışan bu öğrenme kuralında çıktı katmanından geriye doğru girdi katmanına kadar hata kareleri azaltma amacıyla ağırlıklar ayarlanır, bu yöntemle geri yayılım, en küçük ortalama karesel öğrenme kuralı denir (Adıyaman, 2007). Teuvo Kohonen (1982) tarafından geliştirilmiş, yarışmacı öğrenme kuralı olarak da bilinen bir öğrenme kuralıdır. Hebb kuralından farklı olarak bir seferde yalnız bir işlemci elemanın, yani yalnızca kazanan nöronun bağlantı ağırlıkları değiştirilmektedir. En iyi nöron, kendisine komşu diğer nöronların ağırlıklarının değiştirilmesine de izin vermektedir. Komşu sayısı eğitim süresince değişebilir. Eğitim süresince en geniş komşu tanımından en dar komşu tanımına inilir (Bayır, 2003).

Bu kuralların uygulanabildiği üç öğrenme yaklaşımları, denetimli, denetimsiz ve takviyeli öğrenmedir. Denetimli öğrenmede makine öğrenme algoritmalarına neyi öğreneceğini öğreten ya denetimli ya da başka bir yolla neyi

öğreneceği aktarılır (Onan ve ark, 2015). Bu şekilde ağıın verdiği çıktı ile beklenen çıktı arasındaki farka göre tüm ağırlıklar tekrar tekrar ayarlanır ve beklenen ile gerçekleşen arasındaki fark en küçük olana kadar bu döngü devam eder. Delta kuralı ve geri yayılım kuralı denetimli öğrenme algoritmalarına örnek verilebilir. Denetimsiz öğrenme de bilgiler girdi olarak verilir, ağıın kendisinin örüntüyü ve sınıflandırmayı oluşturması beklenir. Girdiler arasındaki matematiksel ilişkiye göre ağırlıklar zayıflatılır veya güçlendirilir. Benzerlik gösteren verilerde aynı veya benzer çıkışlar oluşturulur. Stephen Grossberg ve Gail Carpenter tarafından geliştirilen uyarlanır resonans teorisi ve Kohonen tarafından geliştirilen öz düzenleyici haritası denetimsiz öğrenme yöntemlerindendir. Takviyeli öğrenme denetimli ve denetimsiz öğrenmenin ortak çalışmasına benzemektedir. Denetimli öğrenmede olduğu gibi girdi veriler için beklenen belirli çıktı değerleri bulunmamaktadır ama denetimsiz öğrenmeden farklı olarak da ağıın ulaştığı çıkış değerlerinin uygunluğunu değerlendiren bir ölçüt ile ağıı yönlendirmektedir. Bu özelliği öğretmenli öğrenmeye benzemektedir ama detaylı bir çıktı bilgisi ile girdi bilgisi karşılaştırması yapmamaktadır. Genetik algoritma bu tür öğrenmeye örnek verilebilir.

Tüm bu öğrenme yaklaşımları, çok farklı öğrenme algoritmaları kullanarak sonuçlara ulaşabilmektedir. Bunlara, esnek yayılım, Delta-Bar-Delta, hızlı yayılım, genetik algoritma, yönlendirilmiş rasgele arama, Levenberg-Marquardt metodu, eşleştirmeli eğim, Kuasi-Newton öğrenme algoritmaları ve en çok kullanılan geriyayılım algoritmasını örnek verilebilir. Geriyayılım algoritması detaylı olarak Şekil 3.2’de gösterilmiştir. Geri yayılım algoritması, çok katmanlı algoritmalarda çok sık kullanılan bir öğretme algoritmasıdır. İleri yayılımda giriş nöronlarından en son çıktı nöronuna kadar ağırlıklar ayarlanarak bir tahmin yapılır. Bu tahminle gerçek arasındaki fark hata payıdır. Bu hata payını en aza indirmek için çıktıdan girdiye doğru ağırlıklar ayarlanmaya başlanır ve bu hata farkı minimize edilinceye

kadar sürer. Bu hatanın geriye doğru düzeltilme işlemine geri yayılım algoritması denir (Sağıroğlu, ve ark. 2003). Şekil 3.2 de geri yayılım akış şeması gösterilmiştir.




Şekil 3.2. Geri Yayılım Algoritmasının Çalışma Şekli (Sağıroğlu ve ark, 2003)

Bu çalışmada hasta geliş sıklığını tahmin etmek amacıyla yapay sinir ağları ve geri yayılım algoritmasının yanı sıra yapay zekanın bir alt kümesi olan dokuz adet makine öğrenmesi kullanılmıştır.

3.2.1.7.(1). Tekrarlayan Sinir Ağları


Yapay sinir ağlarının özel bir türü olan tekrarlayan sinir ağları sıralı işlemler üzerine uygulama yapabilmek amacıyla 1982 yılında John Hopfield tarafından keşfedilmiştir. İnsan beynini örnek alan geleneksel yapay sinir ağları tam olarak insan beyni gibi tasarlayamamışlardır. Geleneksel sinir ağları, önceki bilgileri yeni bir bilgiye dönüştürür ve o bilgi o yeni dönüşmüş haliyle sinir ağları içinde devam eder. İnsanlar ise kararlarını verirken geçmişteki düşünceleri silip ya da en baştan düşünmeye başlayarak karar vermezler, aksine önceki cümleleri dikkate alarak bir sonraki cümleyi anlarlar veya bir davranışı anlamlandırırken sadece o davranışı düşünüp karar vermezler, önceki davranışları yorumlayıp son davranışı da bu potanın içinde eritip o son davranışı yorumlarlar. Tekrarlayan sinir ağları yapay sinir ağlarının bir türü olarak bu sorunu çözmeyi amaçlar. Bu bilginin kaybolmadan devam etmesi için bu ağlarda döngüler bulunur. Tekrarlı sinir ağı Şekil 3.3'de sunulmuştur.



Şekil 3.3. Tekrarlı Sinir Ağı

(http://cs231n.stanford.edu/slides/2017/cs231n_2017_lecture10.pdf)

Bu nöron da bilgi oluşturulup bir çıktı elde edilir ama aynı zamanda bu bilgi tekrar aynı nöronda girdi olarak kullanılır. Bu döngüyle bir nörondan diğer nöronlara bilgi gitmesini sağlarken önceki nörona da bilgi aktarmaktadır. Bu, dinamik zamansal davranışları çözümlemesine yarar ve ileri beslemeli sinir ağlarından farklı olarak, tekrarlayan sinir ağları (RNN) kendi giriş belleğini girdilerin rasgele sıralarını işlemek için kullanabilirler Döngüyü açtığımızda aslında geleneksel bir ağdan farksız oldukları gözükecektir (Gürsaka, 2003). Döngüyü açtığımızdaki durum Şekil 3.4’de sunulmuştur.



Şekil 3.4. İleri Beslemede Tekrarlayan Nöron Açılımı

(<https://www.analyticsvidhya.com/blog/2017/12/fundamentals-of-deep-learning-introduction-to-lstm/>)

Sinir ağlarının bir zincir benzeri doğasının olması, ardışık veya sıralı bilgileri yorumlamaya uygun olduğunu da göstermektedir. Son yıllarda tekrarlayan sinir ağları, farklı problemlere uygulanarak çok güzel sonuçlar alınmıştır. Dil tanıma, dil modelleme, çeviri, resim yazısı, tahmin gibi konulara başarıyla uygulanmaktadır. Bu ağların asıl işlevi, sıralı bilgileri işlemektir. Normal sinir ağlarında, tüm girdilerin bağılantısız olduğunu kabul ederiz, tekrarlayan yapıda ise bir dizinin her üyesi için aynı işlevi yapar, çıktı önceki hesapların da çıktılarına

bağlıdır. Tekrarlayan sinir ağlarını, geçmişte hesaplananlarla ilgili bilgi toplayan bellek taşıyormuş gibi düşünebiliriz. Teoride bu yapı uzun geçmişe yönelik bilgileri kullanabilir, ancak uygulamada birkaç adım geçmişi kullanabilmektedir, çünkü gradyan kaybolması problemi yaşanmaktadır. Tekrarlayan sinir ağları kayıp fonksiyonunu minimize etmek için, geri yayılım kullanmakta ve geriye doğru ağırlıkları güncellemektedir. Fakat tekrarlayan sinir ağlarında nöronlarda döngü olduğundan çok katmanlı yapılarda geriye doğru gidildikçe ağırlıkları ayarlamakta problemler yaşanmaktadır. Bu da ağırlık eğitilmesini durdurmaktadır. Özellikle sigmoid fonksiyonu gibi tüm büyük veriyi 0 ile 1 arasına uyumladığı için sigmoid fonksiyonun girdisindeki büyük değişiklik çıktısında çok küçük değişikliğe yol açabilmektedir. Bu problem 1991 yılında Joseph Hochreiter tarafından keşfedilmiştir. Ağırlıklar sondan başa düzeltirken küçük oynamalarla düzeltildiğinden başa doğru gidildikçe ağırlıklar sıfıra doğru azaldıkça eğitim duruyor, ağırlık belki sadece yarısı eğitilebilmiş oluyor. Bu problem en iyi şekilde çözmenin yolu uzun kısa dönemli hafıza olmuştur.

3.2.1.7.(1).a. Uzun Kısa Dönem Hafızası

Tekrarlayan sinir başarısı tamamen LSTM' lerin kullanılmasıyla olmuştur. Standart tekrarlayan yapay sinir ağlarından, özel bir türü olan LSTM yardımıyla oldukça yüksek başarılarla ulaşmıştır. Çünkü, tekrarlayan yapay sinir ağlarının farklılığı, önceki bilgileri mevcut bilgi ile ilişkilendirebilmeleridir. Bazen, doğru tahmin yapabilmek için son bilgiler yeterlidir ve bu oldukça kolaydır. Ama bazen de tahmin yapabilmemiz için çok geçmişteki bilgiye ihtiyaç duyabiliriz. Bu gibi geçmiş durumdaki veriyi kullanabilmek için LSTM den faydalanılmaktadır.

LSTM deki en önemli fark 3 kapıya sahip olmasıdır, bilgiyi tel bir hat gibi taşıırken bu hata bağlı 3 kapıyla alışveriş içindedir. Bu kapılar sayesinde hücre durumuna bilgi ekleyebilir veya silebilir. Sigmoid fonksiyonun 0 ile 1 arasında bir değer vererek bilginin geçmesini sağlar. Sıfır değeri verirse hiçbir bilgi geçemez,

bir değeri verirse tüm bilgiyi geçirmiş olur. LSTM modelinde ilk işlem hangi bilginin unutulacağıdır, bunun gerçekleşmesi unutma kapısında olur. İkinci kısım hangi bilginin tutulacağı işlemidir. Bu işlem iki ayrı kısımdan oluşur. Öncelikle giriş katmanı olarak bilinen bir sigmoid katmanı hangi değerleri güncelleyeceğimize karar verir. Sonraki, bir tanh katmanı yeni aday değerler vektörü oluşturur, Ct, yeni duruma eklenebilir. En son olarak da çıktının iletilme kısmıdır. Burada öncelikle bir sigmoid katmanı hangi bölümlerine çıktı çıkarttığımıza karar verir. <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>

3.2.1.8. Makine Öğrenmesi

Yapay zekanın bir alt kümesi olan makine öğrenmesi 80 yıllarında gelişmeye başlamıştır. Bugün çok sayıda veri ile milyonlarca sayı ile hesaplama yaparak bir hedef ölçütünün en iyi hale gelmesini sağlamak için bilgisayarların programlanmasıdır. Makine öğrenmesi deneyimleri kullanarak, sonuçları iyileştirebilen yazılımlardır. En önemli yeniliği eski yazılımlara fonksiyonu tanımlayıp sonucu isterken, makine öğrenme yazılımlarında ona verdiğimiz bilgilerden fonksiyon üretmesini ve böylece yeni bilgiler geldiğinde bu fonksiyonu kullanarak doğru kestirmelerde bulunmasını istemekteyiz. Bu öğrenmenin en büyük gereksinimi büyük miktarda veridir. Makine öğrenmesinde kendisine verilen verilerin genelde beşte dördünü eğitim ve kalan veriyi test için kullanmaktadır. Burada hem eğitimdeki hata payının hem de testteki hata payının az olması istenir. Makine öğrenmenin de denetimli, denetimsiz ve takviyeli öğrenme tipleri vardır. Makine öğrenmesi algoritmalarının bir kısmı sınıflandırma amaçlıdır. Burada amaç tümörün kanserli olup olmaması, havanın karlı, sağanak yağmurlu, fırtınalı olup olmaması gibi bir durumun kestirilmesidir. Bir kısmı da regresyon analizi yapar, durumun sayısal değerini kestirmeye çalışır. Yağacak kar miktarı gibi. Bir kısmı kümeleme analizi yapar. Gösterilen çiçeğin hangi soya girdiği gibi. Bir kısmı

birliktelik analizi yapar ve böylece seyredilen filimler incelenerek yeni filmler tavsiye edebilir. Kontrol amaçlı makine öğrenmeleri de vardır bunlara örnek de sürücüsüz otomobiller verilebilir. Makine öğrenme problemlerinin çoğunda meyilli azalım algoritması kullanılır. Yapay sinir ağları için geliştirilen geri yayılım algoritması gibi çok önemli bir algoritmadır. Meyilli azalım algoritması da yapay sinir ağlarında kayıp fonksiyonu en aza indirmek için kullanılır.

Meyilli azalım algoritması kısmi türevler olarak kayıp fonksiyonu küçültmeyi hedefler. Türev aldığında doğrunun teğet geçtiği yerin eğimini bulur. Bu bilgi bize o fonksiyonun o noktadaki değişimini verir. Bu değişime göre tartılar tekrar ayarlanır. Epok sayısı bize bu işlemin kaç kez tekrar edileceğini, adım boyu da her ayarlama da değişikliğin ne seviyede yapılacağını bildirir. Bir çanakta eğer sıfır noktasında değilsek türev aldığımızda eğilimden hangi yöne gideceğimizi ve tartıyı ayarlayabiliriz. Eğim negatif ise sağa pozitif ise sola git şeklinde yön alınarak en dip noktanın bulunmasıdır.

Bu çalışmada regresyon amaçlı denetimli öğrenme algoritmaları kullanılmıştır. Kullanılan algoritmalar, Lojistik regresyon, (LR), Karar ağacı (KA), Gradyan arttırımı (GA), Stokastik gradyan regresyon (SGR), Adaboost en yakın k komşu (EYK), Destek vektör makinesi (DVM), Çok katmanlı algılayıcılar (ÇKA), Rasgele ağaç (RA) öğrenme algoritmalarıdır.

3.2.1.8.(1). Karar Ağacı

Karar ağaçları hem sınıflandırma hem de regresyon süreçlerinde kullanılabilen en iyi tahmin modellerinden biridir. Karar ağaçlarında sürekli bir sayıyı hedef alan karar ağaçları regresyon amaçlı kullanılan karar ağaçlarıdır. Karar ağaçları bütün öznitelikleri inceleyerek sonuca ulaşırlar. Her bir öznitelik karar düğümüdür ve oradan dallanma olur. Karar ağaçlarının anlaşılması kolay olup, hem sayısal hem sınıflandırma çalışması yapabilir, uç noktaların çıkması zordur ama buna rağmen aşırı uyma problemi yaşanabilir, bu da eğitim seti dışındaki yeni

bilgilerde olumsuz sonuç verebilir. En iyi özelliğinden birisi de özniteliklerin ne kadar katkı sağladığını bizlere gösterebilir. Bu sebeple aynı zaman da iyi bir öznitelik ayırmacıdır. Özniteliklerden etki oranı az olan öznitelikler algoritmadan çıkarılır, bu da karar ağaçlarını aşırı uyumdan korur. Bu metot karar ağaçlarını sadeleştirir ve tahmin keskinliğini artırır. Karar ağaçlarının açıklayıcı özelliklerinden dolayı, çok daha keskin tahminlerde bulunan fakat daha az açıklayıcı algoritmalara tercih edilir (Alpaydın,2004).

3.2.1.8.(2). Gradyan Artırımı

Bu birleştirme tekniği tahmin modellerinde birden fazla yaklaşımın aynı anda birleştirilerek tek bir teknik gibi kullanılmasının tek bir modelin yaklaşımından daha olumlu sonuçlara ulaşılacağına inanılarak yapılmaktadır. Çünkü topluluğun, sapma ve gürültü faktörünü azaltılacağına inanılır. Bu topluluk kurma işlemi yapılırken farklı yöntemler kullanılabilir, bu yöntemlerden biri artırma yöntemidir. Artırma topluluğunda, tahminler modeller tarafından tek tek yapılır ve her bir modelin sonucundaki tahmin hatalarından bir diğer model öğrenir. Artırma algoritmaları, hata payını ve sapmayı küçültebilen, sıralı işle prensibine sahip başarılı algoritma olup, en zayıf yönü aşırı uyum gerçekleştirebilmeleridir. Gradyan artırma, hem regresyon hem sınıflandırma amaçlı kullanılabilen bir tekniktir. Topluluk diğer tahmin modellerinin sıralı olarak kullanılmasıyla karar ağaçlarına dayanan bir modeldir ve diğer tüm öğretmenli algoritmalar gibi hata farkını en aza indirmeyi amaçlar ve bunu da gradyan iniş kullanarak yapar. Makine öğrenme tekniklerin en güçlü algoritmalarından olup, çok geniş bir yelpazede kullanımı vardır. Uygulamanın ihtiyacına çok farklı kayıp fonksiyonları ile çalışır (Natekin ve ark, 2013).

3.2.1.8.(3). Lojistik Regresyon

Lojistik regresyon özellikle sınıflandırma problemlerinde başarılıdır. Hisse senedinin fiyatının kaç olacağından ziyade fiyatı yukarı mı aşağıya mı gidecek, hasta mı değil mi gibi sorulara cevap aradığımızda yardımcı olacak bir makine öğrenme algoritmasıdır. İkili sınıflandırmalara cevap aldığımız bir algoritmadır. Logit fonksiyonuna uygunluğuna göre bir durumun olma veya olmama ihtimalini belirleriz. Doğrusal olasılık modelinde tahmini değerler; olasılığın koşulu olan 0 ile 1 arasında yer almamaktadır. Bir olayın olma olasılığının, olmama ihtimaline bölünmesiyle üstünlük oranı bulunur. Daha sonra da logit fonksiyonuyla üstünlük değeri yeniden bulunur ve üstünlük değerine süreklilik kazandırılır. (Kaygın ve ark, 2018).

3.2.1.8.(4). Rasgele Orman

Rasgele ağaç öğrenme metodu da bir topluluk öğrenme metodu olup, hem sınıflandırmada hem de regresyonda kullanılabilir. Artırma metodundan farklı olarak birleştirilen modeller sıralı değil paralel olarak çalışırlar ve sonunda her bir modelin çıktısı entegre edilir ve entegre işleminde hiçbir modele üstünlük verilmez, modellerin tahminlerinin ortalaması alınarak nihai sonuç bulunur. Karar ağaçları, eğitim verilerini inceler ve eğitim verilerinden kural oluşturur bu kurala göre test verilerini değerlendirir. Bu kurallar çok sayıda eğer-ise şartından oluşmaktadır(Erdem ve ark,2018). Karar ağaçlarının zayıflığını gidermek için bir çok karar ağacını kullanan, rasgele orman algoritması kullanılmaktadır. Öznitelikler belli bir oranda karar ağaçlarına dağıtıldığından sistem hızlı çalışmaktadır. Aynı zamanda algoritma bir öznitelik üzerinde yoğunlaşamaz. Her karar ağacı büyük veri kümesinden rasgele bir veri kümesi seçer ve bunu dağıtarak kullanır bu da aşırı uygunluğun oluşmasını engeller. Bu rasgele veri kümesinin oluşturulması ve özneliğin dağıtılması karar ağaçlarının birbirine benzemesini engeller ve farklı sonuçlara ulaşılmasını sağlar. Bu özelliklerinden dolayı, tahmin

modellerinde çok başarılı sonuçlar oluşturabilmekte, büyük veri kümeleriyle çok hızlı çalışabilmekte ve eğer eksik veriler varsa bunları tamamlamakta veya eksik veriye rağmen çok iyi sonuçlar üretebilmektedir. Rasgele orman algoritması, özneliliklerle ilintili bir girdi vektörünü incelediğinde birçok regresyon ağacı oluşturur ve bunların ortalamasını alır. Birçok regresyon ağacının birbiri ile korelasyonunu önlemek için girdi verisinden rasgele örnekler alarak eğitime tabi tutar. Örnekler alındıktan sonra örneğe alınan veriler tekrar tüm veri kümesine geri konur ve tekrar örnek alınır (Galiona ve ark, 2015).

3.2.1.8.(5). K-en Yakın Komşu

Hem regresyon hem de sınıflandırmada kullanılabilen karmaşık matematiksel fonksiyonlar içermediğinden anlaması basit ve özellikle sınıflandırma problemlerinde sık kullanılan algoritmalarından biridir. Hesaplama zamanı daha kısa olan, tahmin modellerinde de ortalama bir başarıya sahip olan bir algoritmadır. Bir tahmin yapmak istediğinizde eğitim kümesi oluşturup buradan bir öğrenme çalışması yapmaz, onun aksine tüm veriyi ele alır ve tahmin edeceği girdiye en yakın k veriyi seçer. K kadar değer arasındaki mesafeyi ölçer ve en yakın k değerini bulur. Uzaklık ölçerken Öklid, Manhattan veya Minkowski hesaplama yöntemleri kullanılır. Bu bulunan değerlere göre sınıflandırma problemi ise uygun sınıfa, tahmin modeli ise en yakın değere atanır. Gürültülü verilere karşı oldukça dirençlidir, fakat tüm verilerin tüm durumlarını saklayarak ancak uzaklık ölçebildiği bellek ihtiyacı çok fazla olmaktadır. Zaman serilerinin tahmininde, K-en yakın komşu algoritması zaman serisinin geçmişine bakıyor ve şu andaki şartlara benzer bir durum var ise tahmin en yakın duruma göre yapılır (Pedro ve ark, 2015).

3.2.1.8.(6). Destek Vektör Makinesi

1960'lı yılların sonunda Vapnik tarafından ilk olarak geliştirilen fakat yakın zamana kadar ilgi çekmeyen, fakat daha sonra veri alanında iyi bir tahmin edici olmuş istatistiksel öğrenme teorisine dayalı bir öğretmenli öğrenme algoritmasıdır (Galiona ve ark, 2015). Destek vektör makineleri sınıflandırma ve regresyon için kullanılabilecek bir öğretmenli algoritmasıdır Sınıflandırmadaki başarısı daha iyidir ve genelde bu amaçla kullanılır. Öznitelik adedi kadar boyutlu bir uzayda her veri işaretlenir ve öznitelik değeri ile ilişkilendirilir. Bu uzayda destek vektörlerini ayırır ve sınıflandırma yapılır. Burada amaç ayrı sınıflarda olan noktaların arasındaki mesafeyi en fazla yapmaktır. Birden fazla ayırım da olabilir. Hesaplama güçlüğünü yenmek için ise Kernel fonksiyonu kullanılır, probleme göre farklı Kernel fonksiyonları kullanılabilir. Öznitelik sayısının çok olduğu durumlarda daha fazla etkilidirler. Karar fonksiyonunda bir takım eğitim verisi kullanıldığından bellek ihtiyacı çok fazla olmayan bir algoritmadır. Algoritmanın tasarımında, eğitimin ve testin veriminden, aşırı uyumdan ve parametrelerin ince ayarından kaçınılır (Cristianini ve ark, 2004).

3.2.1.8.(7). Çok Katmanlı Algılayıcılar

Denetimli bir öğrenme algoritması olup, hem regresyon hem de sınıflandırma problemlerinde kullanılabilir. N boyutlu bir girdi ve m boyutlu bir çıktı içeren özniteliklerin olduğu veri kümesinden öğrenerek bir fonksiyon oluşturan ve hedef çıktıları doğru tahmin etmeye çalışan bir algoritmadır. Bu fonksiyon doğrusal veya doğrusal olmayan bir yaklaşım olabilir. Lojistik fonksiyondan farklı olarak, girdi ve çıktı katmanının yanı sıra girdi ve çıktı katmanlarının arasında gizli katmanlarda bulunur. Doğrusal olmayan problemlerin çözümünde oldukça başarılıdır. Yalnız bazen ideal çözüm yerine, yerel çözüm bulabilir; hiper parametrelerin ayarlanması gerekebilir ancak bu ayarlamalar deneme yanılma ile yapıldığı için ideal çözüme ulaşmak zor olabilir. Öznitelik

kümesinden çok etkilenir, öznitelik kümesi eniyilemesi gereklidir. Eğitim aşaması uzun sürmesine rağmen test aşaması oldukça hızlıdır. Minimum hatayı bulmaya çalışırken bölgesel minimumlara takılma oranı çok düşüktür (Moralı ve ark, 2007).

3.2.1.8.(8). Stokastik Gradyan Regresyon

Stokastik gradyan iniş algoritması, gradyan iniş gibi sürekli parametreleri düzelterek kayıp fonksiyonunu minimize ederek asıl hedefe ulaşmaya çalışan bir algoritmadır. Gradyan iniş problemlerinde tüm veri dikkate alınarak bir gradyan oluşturulurken, stokastik gradyan da tüm veri değerlerinden rasgele oluşturulmuş bir veri kümesinden yapılan bir tahmin ile asıl gradyanın yaptığı işlem yapılır. Gradyan iniş problemlerinde her veri için güncelleme yapılırken tüm ağırlıklar yeniden hesaplanır, bir defada güncellemesini yaparak çok hızlı çalışır ve öğrenme hızını yavaşlatmak küresel ideal değeri yakalamasını sağlar. Yalnız, bu algoritmanın en düşüğü hesaplamasının sade yaklaşımı gürültü etkisinden çok etkilenmektedir (Bonnabel, 2013).

3.2.1.8.(9). Adaboost,

Adaboost algoritması zayıf algoritmaların birleştirilerek oluşturulmasıyla oluşan hesaplama yöntemi karmaşık olan bir algoritmadır. Sürekli ve kesikli Adaboost algoritmaları bulunur. Adaboost öncelikle ana veriye bir tahmin modeli oluşturur, daha sonrada diğer modellerin ağırlıklarını bir öncekinin hatalarına göre ayarlayarak son tahmini yapar. Her itirasyonda iyileştirme devam eder (Hu ve ark, 2008).

3.2.2. Öznitelik Seçimi

Yapay zeka ile öğrenmede birbirinden bağımsız her bir ölçülebilir ve gözlemlenebilir özelliğe “öznitelik denir. Tahminleri veya sınıflandırmaları yapabilmek için faydalanılan bir değişkendir. Öznitelik kümesi oluşturulurken

gözlemlere bağlı, uzman görüşüne bağlı ya da deneme yanılma yoluyla oluşturulabilir. Makine öğrenmeleri daha büyük ve karmaşık problemlere yöneldikçe, ilgili özniteliklere odaklanabilme problemi çok daha fazla önem kazanmaktadır. Öznitelik konusu iki kısma ayrılır. Birincisi, hangi bilgiler öznitelik olarak kullanılabilecek, diğeri ise bu seçilen özniteliklerin kombinasyonu nasıl olacak, ideal öznitelik kümesi nasıl belirlenecektir. Öğrenme algoritmasına katkı sunan ve sunmayan öznitelik ayıklanması işlemi makine öğrenmesinin merkez problemlerinden biridir. Bu konuyla ilgi birçok algoritma bulunmaktadır (Blum ve ark, 1997).

Öznitelik seçimi doğru yapılırsa öğrenme algoritmalarımız daha hızlı sonuç verebilecek, modelin karmaşıklığı azalacak, sonuçlar daha anlaşılır olacak, tahmin başarısı artacak ve aşırı uyum probleminin yaşanma olasılığı azalacaktır. Bu ideal öznitelik kümesini sağlamanın 3 ayrı genel metodu bulunmaktadır. Sarmal yöntemler, filtreleme yöntemleri ve gömülü yöntemleri öznitelik seçim yöntemlerinin tamamını içerir. Filtreleme yöntemi en eski yöntemlerden biri olup, bu yöntemde uzaklık, bilgi, bağımlılık ve tutarlılık değerleri gibi istatistiksel ölçütlere dayanan fonksiyonlar yardımıyla öznitelik belirlenmektedir. Filtreleme yöntemiyle çalışan ki kare testi, fisher skor, t sckor veya Welch t-İstatistiği gibi yöntemlerde öznitelik belirleme işlevi birbirine çok benzerdir. Her özellik için ölçüm fonksiyonu aracılığıyla bir değer verilmekte ve verilen bu puanlar içerisinde en iyi puana sahip olanlardan alt küme oluşturulmaktadır. Sarmal yöntemlerde, farklı öğrenme algoritmaları kullanılarak en iyi performans gösteren özellikler belirlenmektedir. Sarmal yöntemler, filtreleme yöntemlerine göre daha iyi sonuç vermelerine rağmen hesaplama işlemleri daha maliyetlidir. Ardışık ileri yönde seçim, ardışık ileri yönde kayan seçim, ardışık geri yönde kayan seçim, L Ekle - R Çıkar gibi yöntemler örnek verilebilir. Gömülü yöntemler ise özellik seçimi algoritmasını içeren makine öğrenmesi algoritmaları ile çalışırlar. Gömülü yöntemler de filtreleme yöntemleri gibi hızlı değildir. Örnek olarak, karar

ağaçlarını, destek vektör makinelerini verebiliriz. Gömülü yöntemler sarmal yöntemler gibi daha yüksek bir hesaplama maliyetine sahiptir (Budak, 2018). Sarmal yöntem makine öğrenme yöntemleri ile özniteliklerin katkısını hesaplıyor ve özniteliğin katkısı yoksa eleyerek nitelikli kümeye ulaşıyor, filtreleme yönteminde ise bu sezgisel yöntemlerle yapılıyor ve herhangi bir algoritma ile test edilmiyor (Hall ve ark 1999). Kapsamlı işleyişinden dolayı sarmal yöntemlerin daha iyi öznitelik kümesi kurduğu düşünülmektedir, yalnız sarmal yöntem filtreleme yöntemine göre daha yavaştır (Ramaswami ve ark, 2009). Korelasyon faktörlerini kullanan sarmal yöntemler öznitelik kümesini oluşturma konusunda çok daha hızlıdır (Kabir ve ark, 2008).


Bu çalışmada, sarmal yöntemlerden kapsamlı öznitelik seçim kuralı kullanılmıştır. Böylece tüm kombinasyonlar denenerek en iyi öznitelik kümesine ulaşılmıştır.

3.2.3. Simülasyon

Simülasyon, sistemlerin bilgisayar yardımıyla modellenmesini sağlar. Sistem yapılacak çalışmanın amacına göre simülasyon modeli şekillenir. Bir sistem için toplanan veriler, bir başka sistemin alt kümesini oluşturabilir. Sistemler kesikli ve sürekli olabilir. Bankadaki müşteri sayısı bankaya gelince artar veya müşteri çıkınca azalır bu kesikli modele örnektir, ama havada uçan bir uçak da sürekli sisteme bir örnektir.

Gerçek sistemle denemeler yapabiliyorsak burada sistemin doğruluğunu tartışmadan sonuçlara ulaşabiliriz. Ama bu çok maliyetli olabilir veya henüz sistem olmayabilir bu durumlarda, sistemin modellenmesi gerekir. Sistemin fiziksel küçültülmüş bir hali oluşturulabilir. Uçak kokpitinin bir örneği veya yüzme havuzunda bir denizaltı gibi. Burada modelin doğruluğu ve sürekli senaryolara göre değişimi zor olabilmektedir. Bu sebeple modelin matematik modeli daha çok tercih edilmektedir. Matematik modellerde de analitik çözümler elde edilebilir. Eğer

model yeteri kadar basit ise analitik çözümler yeterli olabilir. Fakat, birçok sistem karmaşıktır, bu modeli matematiksel yaklaşımla ifade etmek daha da karmaşık ve çok zor olabilir, bu durumlarda modeli simülasyon ile çözümlemek gerekmektedir. Bilgisayar yazılımları ile sistemdeki akışı gerçeğe uygun olarak bilgisayar ortamında oluşturma, oluşturulan modelin gerçek sisteme benzerliğinin onaylanması ve doğrulanmasını sağladıktan sonra değişik senaryolara göre sistemi bilgisayar ortamında yaşatarak, olası değişikliklerin olumlu veya olumsuz yönlerini önceden görebilme, sistemi analiz edebilme ve sistemde iyileştirmeler yapabilme yöntemine simülasyon denir (Law, 2007). Şekil 3.5 'de sistem inceleme çalışma metodu sunulmuştur.



Şekil 3.5. Sistem İnceleme Çalışma Metodu (Law, 2007)

Yöneylem araştırma modellerinden biri olan bu yöntem, dünya genelinde karmaşık sistemlerin çözümünde oldukça popülerdir. Sosyal bilimlerde de mühendislik alanında da kullanılabilmektedir. Simülasyonun bu kadar çok kullanılıyor olmasının en önemli sebebi, çok karmaşık sistemleri modelleyebilmesidir. Bir diğer sebebi de gelişen bilgisayar sektöründe fayda fiyat analizinde fiyat önemsizleşmektedir. Simülasyon yazılımındaki gelişmeler sayesinde, program esnek ve kullanılması çok kolaylaşmış olup hızlı ve doğru karar veren bir program olması da yaygın kullanılmasının bir başka sebebidir. Simülasyon programları, 1950-1960 yılları arasında havacılık ve çelik şirketleri tarafından kullanılabilen, Fortran'da yazılan pahalı bir uygulamayken, bugünkü anlamında kullanımı 1970-1980 yılları arasında başlamış, bilgisayar yazılımlarının ucuzlaması ve daha hızlı olması ile diğer endüstri kollarına da yayılmış, ancak zor durumların anlaşılması için otomotiv ve ağır endüstri de nadiren kullanılmıştır. 1980 sonrasında kişisel bilgisayarlarda da kullanılmaya başlanmış ve 1980 yılının sonunda büyük yatırımlara başlanmadan önce birçok büyük firma tarafından kullanılmaya başlanmıştır. 1990 yıllarından sonra, daha iyi animasyon teknikleri olması, kullanımının kolaylaşması, bilgisayarların hızlanması ve diğer programlarla kolayca entegre olabilmesi simülasyonun kullanımı çok arttırmış ve yaşayan simülasyon modellerine geçilmiştir. Daha projenin en başında simülasyon modellemesi yapılmakta, proje yaşadıkça modelde buna göre güncellenmektedir. Bilgisayarların ve yazılımların çok hızlı gelişmesi, yakın gelecekte simülasyonun nerelere gelebileceğini tahmin etmeyi zorlaştırmaktadır; ama simülasyon yazılımı, otomatik istatistiksel analiz yapabilen değişiklikler öneren programla entegre çalışarak sistem iyileştirmeleri yapabilecektir (Kelton ve ark, 2004).

Birçok farklı bilgisayar simülasyon modellemesi bulunmaktadır. Sistem dinamikleri, kesikli olay simülasyonu, etmen tabanlı simülasyon modellerini bunlara örnek verebiliriz. Sistem dinamikleri ile kesikli olay simülasyonu farklı durumlar için kullanılırlar ve kesikli olay simülasyonu ile etmen tabanlı

simülasyonun karşılaştırılmasında hangisinin gerçek problemi daha iyi resimlediği konusu hala tartışmalıdır (Brailsford, 2014). Kesikli olay simülasyonun da, zamanın belli noktalarında sistem değişkenleri değişir. Bu noktalarda olay oluşur, bu da sistemin durumunu değiştirir. Hastanın acil sisteme gelmesi, ayrılması gibi durumlar, sistemin durumunu değiştiren olaylardır (Law, 2007). Kesikli olay simülasyonunda olayların değişimi sırasında sistemde her şey sabittir. Bu simülasyona iki yaklaşım bulunmaktadır. Birinde olaylar sürekli sisteme çok benzer ve olaylar dinamiktir, fakat genelde gelecekteki durumlarda tesadüfi gelişme olmaz; ikinci yaklaşımda ise dinamik ve rasgele olmasıdır (Marko ve ark, 1992).

Simülasyon modellemesinin çalıştırabilmesi için, hasta geliş sıklığı, tedavi süresi veya laboratuvar süresi gibi zamanların tanımlanması gerekmektedir. Bunun da yazılım tarafından olasılık dağılımlarına göre rasgele atanması gerekmektedir. Bu olasılık dağılımları sürekli, kesikli olabilir ve bazen de gözlemlere dayanan basit dağılımlar kullanılabilir. Kesikli dağılımlara, Bernoulli dağılımı, Binom dağılımı, Geometrik dağılım, Poisson dağılımı, Düzgün dağılım; sürekli dağılımlara, Sürekli düzgün dağılım, Üçgen dağılım ve Üssel dağılım örnek verebiliriz (Law ve ark, 1982).

3.3. Model Geliştirme

Acil servislerde sağlık hizmetlerinin kalitesini artırmak amacıyla kaynak optimizasyonu yapmayı amaçladığımız bu çalışmada kaynak eniyilemesi için yöneylem yöntemlerinden biri olan simülasyon modelinden faydalanılması amaçlanmıştır. Simülasyon modelinin doğru sonuçlar verebilmesi amacıyla simülasyon modelimizde kullanacağımız hasta geliş sıklığı girdisinin çok keskin tahmin edilmesi amaçlanmıştır. Bunun için YZ tekniklerinden olan yapay sinir ağları modeli ve makine öğrenme algoritmaları geliştirilmiştir. Ayrıca bu yapay zeka tekniklerinin başarısında önemli rol oynayan öznelilik kümesinin optimize

edilmesi için Phyton'da bir yazılım hazırlanmıştır. Özniteliklerin alt kümesinin optimizasyonu yapıldıktan sonra, bu öznitelik alt kümesini kullanarak keskin tahminler yapabilen yapay sinir ağları modeli ile dokuz adet makine öğrenme algoritması oluşturulmuş ve buradan elde edilen hasta geliş sıklıklarının tahminini girdi olarak kullanılarak, yatak sayısını optimize etmek amacıyla kesikli olay simülasyon modeli geliştirilmiştir.

3.3.1. Yapay Sinir Ağları Modelinin Geliştirilmesi


Yapay sinir ağları ile yaklaşık her problem çözülebilir. Yalnız, uygun mimariyi oluşturmak şarttır. Uygun mimari için, uygun YSA seçimi seçilen öznitelikler, katman sayısı, nöron sayısı, aktivasyon fonksiyonun seçimi, eğitim ve test kümelerinin belirlenmesi ve normalleştirme seviyelerinin belirlenmesi için maalesef yöntemler kısıtlıdır. Bu seçimlerde yeterli yönlendirici bilgiler bulunmamakta ve deneme yanılmaya başvurulmaktadır. Mimarinin tasarımı düzgün yapılamazsa, sonuçlar beklenen düzeyde çıkmayabilir ve çok uzun hesaplama zamanı oluşabilir. Tasarımda kombinasyon çok önemlidir, bir tasarımda kullanılan aktivasyon fonksiyonu çok başarıyla bir başka parametrelerin kombinasyonunda başarısız olabilir.

YSA tipi ve türünü seçmek başarının en belirleyici parametrelerindendir. Aşağıdaki korelasyon tablosunda da görüldüğü gibi hasta geliş sıklığı değeri zamana çok bağımlıdır. Bu da bize sıralı bilgiyi tahmin etmemiz gerektiğini göstermektedir. Bu çalışmada hedef değerlerini tahmin edebilmek için sıralı bilgiyi en iyi tahmin etme özelliğinden dolayı tekrarlanabilir yapay sinir ağları ve bu ağın başarısını arttıran LSTM türü seçilmiştir.

YSA'nın tipinden sonra YSA'nın başarısını etkileyen parametrelerden biri optimizasyon algoritmasının belirlenmesidir. Ağ yapısını öğrenme algoritmasından önce seçmek, öğrenme algoritmasının seçimine yardımcı olmaktadır. Seçeceğimiz öğrenme algoritmasının aşırı öğrenme sorunu çıkartmaması gerekmektedir. Bu

çalışmada ADAM optimizasyonu kullanılmıştır. ADAM derin öğrenme algoritmaları için geliştirilmiştir.

Aktivasyon fonksiyonu uygulanması YSA'nın bir diğer olumlu özelliğidir, bu sayede doğrusal olmayan problemlerin çözümünü sağlamaktadır. Tasarıma uygun olan, aktivasyon seçimi tahmin gücünü artırır. Uygun bulunamadığında tasarlanabilir. Bu çalışmada şekil 3.6.'da gösterilen Leakly ReLU transfer fonksiyonu kullanılmıştır. Çünkü, ReLu gibi hızlı çalışan bir aktivasyon bölgesinde değer sıfır olmakta ve türevi de sıfır olduğu için o noktalarda öğrenme durmaktadır. Sızdıran ReLu (Leakly ReLU) da sıfır verilecek bölgelere sıfıra yakın bir değer verilirse, o bölgelerde türev sıfır olmayacağından öğrenme devam edecektir.



Şekil 3.6. Sızdıran ReLU Aktivasyon Fonksiyonu

YSA'ların en anlamlı farkı doğrusal olmayan problemlerin çözümünü yapabilmeleridir. Bunun için veriler bir normalizasyon işleminden geçirilirler. Seçilen yöntemde YSA'nın performansını arttıracak bir yöntemdir. Normalize


edilmiş veriler değerlendirilmiş toplam değerlerin oluşturacağı olumsuzlukları önlemiştir. Bu normalleştirme işleminden sonra verilerin ya 0 ile 1 yada 0 ile -1 arasında olması istenir. Verinin uç noktalara gidebildiği problemlerde normalleştirme işlemi çok daha önemlidir. Bu çalışmada normalleştirme için Min-Max ölçeklendirilmesi kullanılmıştır. Min-Max ölçeklendirilmesi $x_{\text{norm}} = x - \frac{x_{\text{min}}}{x_{\text{max}}} - x_{\text{min}}$ formülü ile yapılır.

YSA eğitiminden önce normalleştirme başlar, 0 ile 1 arasındaki verilerle giriş ve çıkış işlemleri yapılır. Tüm işlemler bittikten sonra çıktı verileri ters normalleştirme işlemi uygulanarak gerçek tahmin verilerine ulaşılır. Bu ölçeklemede aktivasyon fonksiyonları da kullanılır.

Ara katman sayısı ve ara katman nöron sayılarını belirlemek için genel bir kural bulunmamaktadır. Literatürde 2 ara katman kullanılması üzerine yaygın bir kanı bulunmaktadır. Bu konu, bu çalışmada denemeler yapılarak çözümlenmiştir. Olabildiğince az katman sayısı ve nöron sayısı ile belirlenmeye çalışılmıştır.

Ara bağlantılar da tasarımda bir diğer önemli parametre olup bu çalışmada geri yayılımı, gradyan iniş tekniği ile ağırlık performans fonksiyonunun minimum değerinin bulunmasına çalışılmıştır. Öğrenme fonksiyonunun başarısının bağlı olduğu bir faktör olan performans fonksiyonu da ortalama mutlak yüzde sapması seçilmiştir.

Modelin geliştirilmesinde yukarıda bahsedilen konulara dikkat edilmiş olup, iki ara katmanlı, 300 gizli nöronlu, öğrenme hızı 0,0005 olarak ayarlanmış aktivasyon fonksiyonu olarak Leaky ReLU ve için ADAM optimzer'ın seçildiği tekrarlayan yapay sinir ağlarının LSTM türü tasarlanmıştır. Şekil 3.7.'de tekrarlanabilir yapay sinir ağlarının modeli sunulmuştur.



Şekil 3.7. Tekrarlayan Sinir Ağlarının Modeli

3.3.2. Makine Öğrenme Algoritmasının Geliştirilmesi

Bu çalışmada tüm makine öğrenme algoritmaları Payton yazılımında Sciki-learn paketinin makine öğrenme algoritmalarını içeren geniş bir kütüphanesi bulunmaktadır. Algoritmanın tüm parametrelerini değiştirmek, istediğimiz öz nitelikleri yüklemek mümkün olmaktadır. Scikit-learn ile bir nesnenin hangi kategoriye ait olduğu tespit edilebilir. sınıflandırma, nesneyle ilgili bir özelliğin değerini tahmin edebiliriz, regresyon, benzer nesneleri bir gruba koyabiliriz, kümeleme, dikkate alınacak tesadüfî değişkenlerin azaltılması, boyut azaltılması, parametre ve model seçimi yapabiliriz, model seçimi ve öz nitelik kümesi oluşturma ve veri normalleştirme yapabiliriz, ön işlem paketleri bulunmaktadır. Bu çalışmada tahmin çalışması yapılmış ve regresyon paketinden 9 makine öğrenme algoritması kullanılmıştır.

3.3.3. Simülasyon Modelinin Geliştirilmesi

Mevcut sistemdeki durum acil servisteki aşırı kalabalığa çözüm olmadığından sisteme yeni bir kaynak ilave edilmesi veya sistemin akışının değiştirilmesi ve bir simülasyon modelinin yapılması gerekmektedir. Bu simülasyon modelinin yapılmasının birinci adımı, mevcut sistemin detaylı bir

incelenmesinin yapılmasıdır. Bundan dolayı acil servise gelen hastanın acil servisteki durumu incelendi; acil servise geldikten sonra hastanın acil durumuna öncelik verme sistemi gözlemlendi; hastanın acil servise gelme sebepleri, hangi hastalıktan gelen hasta sayısının yüzde oranı ve acil servis birimine geldikten sonra yapılacak işlemlerin rotası, bu rotaların kullanım oranı ve işlem süreleri ile ilgili veri toplandı. Ayrıca doktor sayısı, hemşire sayısı, yatak sayısı gibi kaynakların sayısı belirlendi. Toplanan bu veriler ve sonuçlar hastane yönetimi ile paylaşarak görüşleri ve dikkat etmemiz gerek konularla ilgili sürekli bilgi alışverişinde bulunuldu.

İkinci adım ise simülasyonu yapılan sistemde problemin tam olarak tanımlanması ve bu problemdeki çözümü ölçecek bir hedefin oluşturulmasını içermektedir. Bu çalışmada problem, kaynak planlanmasının doğruluğu yönünde yatak sayısının optimizasyonudur. Yatak sayısının ideal sayısı da, performans ölçüğümüz olan hasta bekleme süresidir. Problemin ve performans ölçüğünün tam olarak tanımlanması da bize simülasyonla oluşturulacak deneme senaryolarını belirlememize yardımcı olmaktadır. Bu çalışmada yatak sayısı değiştirilerek, acil servis birimindeki kalabalığın değişimi izlenecektir. Bu aşamadan sonra genel bir simülasyon modeli ile herhangi bir sistemi modelleyip verileri değiştirerek çok hızlı sonuçlara ulaşmak mümkündür. Bu adımla beraber modelin oluşması için simülasyonun amacı, simülasyon yapılacak sistemin tanımı, simülasyon modelinin girdileri, çıktıları belirlenmiş olmalıdır.

Modelin yapısının oluşturulmasından sonra simülasyon modelinin doğrulanması ve onaylanması gerekmektedir. Simülasyon modelinin doğrulanması, modelin tasarlandığı gibi çalışması demektir. Modelin tasarlandığı gibi çalışma işlemi modeller büyüdükçe oldukça karmaşık bir problem haline gelebilmektedir. Karmaşık ve büyük modellerde birçok olayın aynı anda gerçekleşmesi ve bu olayların kesişmesi, bir olayın çıktısının bir diğerinin girdisi olması izlenebilirliği çok zorlaştırmaktadır. Modeli doğrulamanın kesin bir yolu olmamakla beraber,

modeli farklı senaryolarla çalıştırarak sonuçlar incelenmiştir. Çalıştırılan farklı senaryolara göre beklenen sonuçları vermesi modelin doğruluğunu göstermiştir. Modelin doğruluğu, hem modelin yapıcısı hem de modelin kullanıcısı arasında verilmesi gereken bir karar olduğu için de model detaylı olarak hastane koordinatörü ile paylaşılmış ve onların da modelin tasarlandığı gibi çalıştığına dair görüşleri ve onayları alınmıştır. Simülasyon modelinin yatak sayısı 7 senaryosuna göre çalıştırıldığında hasta kalış süresi 196 dakikadır. Hastane kayıtları incelediğinde, hastane kayıtlarındaki hasta kalış süresi ile simülasyon sonuçları arasında kayda değer bir farka rastlanmamıştır. Bu da simülasyonun gerçek sisteme benzerliğini doğrulamaktadır.

Simülasyon modellerinin birden fazla çalıştırılması, simülasyon sonuçlarının çok daha güvenilir olmasını sağlar ve güven aralığının genişliğini belirler. Yeterli replikasyon sayısını bulmak için genellikle sabit örnekleme metodu veya sıralı metot kullanılır (Law, 2004). Davis ve ark. (2004), yaptıkları çalışmada sıralı metodu kullanmışlardır. Bu çalışmada replikasyon sayısı sıralı kullanarak belirtilmiştir. Sıralı metodun adımları aşağıdaki gibidir.

$\bar{X}(n)$: Örnek ortalaması

$\delta(n,a)$: Güven aralığı yarı uzunluğu

$s^2(n)$: Örnek varyansı

0α : Anlamlık seviyesi

$t_{i-1,1-\alpha/2}$: t tablo değeri

γ' : $\delta(n,a) = t_{i-1,1-\alpha/2} \sqrt{\frac{s^2(n)}{n}}$;

Hesaplama yönteminin adımları aşağıda sunulmuştur.

Başlangıç replikasyon sayısı 2 seçerken $n_0 \geq 2$ ve $n = n_0$


1. $X_1, X_2, \dots, X_n$ verisinden $\bar{X}(n)$ ve $\delta(n, a)$ hesapla
2. Eğer $\delta(n, a)/\bar{X}(n) \leq \gamma'$, μ için $\bar{X}(n)$ i' nokta tahmin olarak kullan ve dur.

Bu noktada; $I(\alpha, \gamma) = [\bar{X}(n) - \delta(n, a), \bar{X}(n) + \delta(n, a)]$, yaklaşık olarak $100(1-\alpha)$ μ için yüzde güven aralığı istenilen hassasiyettir.

Aksi durum da, n faktörü $n+1$ ile değiştir ve yeni bir simülasyon replikasyon yap ve birinci adıma geri dön.

Sıralı yöntem kullanılarak replikasyon sayısı 5 olarak hesaplanmıştır.

Simülasyon modellerinin kararlı duruma geçmesini sağlamak, yanlılığı engelleyebilmek ve güvenilir sonuçlara ulaşmak için simülasyonun belli bir sayıda çalıştırılması gerekmektedir. Bu kararlı hale gelme süresinin (warm-up) belirlenmesi için Welch grafik metodu kullanılmıştır (Kadı ve ark, 2016). Kesikli olay simülasyonun tasarım adımları Şekil 3.8'de gösterilmiştir.



Şekil 3.8. Kesikli Olay Simülasyon Modelinin Tipik Bir Akış Şeması



4. BULGULAR VE ARAŞTIRMALAR

Bölüm 3'te anlatılan yöntem ve metotlarla Ceyhan Özel Çınar Hastanesinde acil servis biriminde kalabalık problemini çözmek için bir vaka çalışması yapılmıştır. Her hastanedeki ve bölgedeki acil servis biriminin kendine özgü özelliği bulunur. Bazı hastanelerde hafta sonu yoğunluk olmakta, bazı birimlerde tatil zamanlarında yoğunluk olmaktadır. Hava şartlarının ağır olduğu bölgelerde kar, fırtına gibi hava şartları, acil servisteki kalabalığın belirleyicisi olabilmekte, havanın ılıman olduğu bölgelerde hava durumunun hasta gelişine etkisi olmamaktadır. Bu çalışmanın gerçekleştiği acil servis biriminde, hasta gelişlerinin öğleden sonra 5 ile gece 12 arasında yoğunlaştığı, en yoğun olduğu zamanın ise akşam 8 ile akşam 11 arasında olduğu tespit edilmiştir. En tenha zaman sabah 4 ile 6 arasında gözlemlenmiştir. Acil servis birimine gelenlerin %36'sının hafta sonu gelmekte olduğu, kış ve yaz aylarında hasta gelişinde yükselme olduğu görülmüştür. Buna rağmen hasta gelişinin sonbaharda kışa göre %13 oranında azaldığı, resmi tatillerde, saatlik hasta geliş oranı 5,45 kişi iken, normal günlerde hasta geliş 3,31 kişi olarak gerçekleştiği tespit edilmiştir. Her hafta sonu, mevsim veya tatilden bağımsız olarak yaklaşık aynı hasta sayısı gelmekte olup, bu da hafta içi normal bir günde gelen hasta sayının 1,5 katı kadar olmaktadır.

Bu çalışmanın ilk adımı yapay sinir ağları ve makine öğrenme algoritmaları gerçekleştirilerek, hasta geliş sıklığı tahmin edilmesidir. Hasta geliş sıklığı, 1 yıllık veri ile saatlik ve günlük, 5 yıllık veri ile saatlik olarak tahmin edilmiştir. Günlük olarak tahmin yapılmasının amacı modelimizin ne kadar doğru çalıştığını anlamak ve literatürdeki sonuçlarla karşılaştırmaktır. Saatlik tahminin yıllık olarak 5 yıllık veri ile yapılmasının amacı ise büyük veri kümesinin sonucu nasıl değiştireceğini gözlemek, ayrıca öznitelik kümesindeki değişimi incelemektir.

Büyük veri kümesinin sonucu olumlu etkilediği ve veri yapısının değişmesinin de öznitelik kümesini değiştirdiği tespit edilmiştir.

4.1. Bulgular

Hasta geliş sıklığı tahmininin yapılabilmesi için denetimli makine öğrenme yöntemleri kullanıldığından ideal öznitelik kümesi belirlenmesi ve ikinci adımda da, ideal öznitelik kümesi belirlendikten sonra da en iyi sonuç veren makine öğrenme algoritmasının bulunması gerekir.

4.1.1. Öznitelik Kümesinin Bulunması


Yapılan literatür çalışması ve hastane çalışanlarının görüşleri ve gözlemlerimiz temel alınarak acil servise gelen hasta sayısına etkisi olduğunu düşündüğümüz öznitelikler aşağıdaki gibi belirtilmiştir.

- | | |
|-------------------------------|-----------------|
| - Haftanın günleri(Pzt. Salı) | - Tatil günleri |
| - Hafta sonu | - Rüzgar |
| - Mevsim | - Yağmur |
| - Haftanın günleri | - Nem |
| - Gün içi saat | - Sıcaklık |

Bu öznitelik kümesinin hem hedefle ilişkisini görmek hem de birbiriyle ilişkisini incelemek için korelasyon analizi yapıldı. Korelasyon sonuçları Şekil 4.1.'de verilmiştir.

Bu sonuçlar incelendiğinde günün saatleri özniteliğinin hasta geliş sıklığı ile en fazla ilişkili olduğu görülmektedir. Korelasyon sarmal yöntemlerin temelini oluşturmaktadır. Fakat literatürde yaptığımız araştırmalar korelasyon temelli veya başka türlü eleme yöntemlerinin ideal sonuç vermeyebileceği ve ideal olmayan öznitelik kümesinin de algoritmaların başarısını azaltmaktadır. Bu sebeple

kapsamlı öznitelik seçim yöntemine başvurulmuş ve korelasyon veya filtreleme yöntemi kullanılmamıştır.



Şekil 4.1. Özniteliklerin Hedefle İlgili Korelasyon Sonuçları

Python yazılımda oluşturduğumuz yazılımla tüm öznitelik kümelerini Rasgele Orman makine öğrenme algoritması ile deneyerek ideal öznitelik kümeleri bulunmuştur. Şekil 4.1'deki korelasyon tablosunu incelediğimizde, nem ve sıcaklığın hasta geliş sıklığı ile ilişkisinin tatil ve mevsimlere göre çok olduğu görülmektedir. Kapsamlı öznitelik seçim çalışması ile, saatlik hasta geliş tahmini için en iyi öznitelik kümesi saatlik geliş oranı, hafta içi, tatil günleri ve mevsim olarak belirlenmiştir. Buna rağmen, günlük hasta geliş sıklığı tahmini için ideal öznitelik kümesi sıcaklık, nem, haftanın günleri, hafta içi, mevsim ve tatil günleridir. Bu ideal öznitelik kümesinin 5 yıllık veri ile 1 yıllık veri farklı sonuçlara ulaştığı belirlenmiştir. Buda öznitelik kümesinin kapsamlı öznitelik yöntemi ile belirlenmesi gerektirdiğini, çünkü ideal öznitelik kümesinin her şeyden önce veri yapısına bağlı olduğunu göstermiştir. Bu çalışmadaki veri boyutu için bilgisayar hesaplama süresi çok kısadır. Çok karmaşık ve büyük veri yapısı olmadığı sürece kapsamlı öznitelik yöntemini kullanmak, ideal öznitelik kümesini belirlediğinden makine öğrenmesi algoritmalarını çalıştırırken zaman kazandırır.

4.1.2. En İyi Makine Öğrenme Algoritmasının Bulunması

En iyi tahmini yapabilecek makine algoritmasının tespit edilebilmesi için, hem algoritmanın tasarımından hem de veri yapısından etkilenmesinden dolayı geniş bir yelpazede makine öğrenme algoritması kullanılmıştır. İlk önce 1 yıllık veri ile günlük olarak tahminler hesaplanmış ve sonuçlar Çizelge 4.1.'de gösterilmiştir. Çizelge 4.1.'de gösterilen tablo incelendiğinde, LSTM modelinin %16,79 ile en iyi sonucu verdiğini, gradyan artırımının %20,19 ile en iyi ikinci sonucu verdiğini ve karar ağacının da %26,1 ile en kötü sonucu verdiğini görülmüştür. Karar ağacının 1 yıllık veri ile saatlik tahminde LSTM kadar iyi sonuç verdiğini saptanmıştır. Bu da veri yapılarına göre makine öğrenme algoritmalarının farklı sonuçlar verdiğini ve bundan dolayı birbirinden farklı çok

sayıda algoritma kullanmamızın başarılı tahmin sonucuna ulaşılması açısından ne kadar önemli olduğu sonucuna ulaşılmaktadır.

Çizelge 4.1. 1 yıllık veri ile 10 farklı makine algoritmasının 10 katlamalı çapraz doğrulama yöntemiyle elde edilen günlük hasta geliş sıklığı tahmin verilerinin OMYH istatistik sonuçları

MKÖ	LSTM	DR	KA	GA	SA	AB	K- EYK	DVM	ÇKA	RO
Ortalama	16,79	20,83	26,1	20,19	21,04	22,24	20,54	21,57	21,81	21,88
SS	6,49	6,27	7,33	6,26	6,06	6,6	6,68	6,75	7,37	6,39
En Küçük	11,78	14,18	14,28	13,37	14,51	13,75	13,94	14,38	14,05	13,2
En Büyük	35,05	30,47	36,54	29,69	30,5	31,05	32,13	32,31	32,31	30,63

SS : standart sapma

Acil servisin çok dinamik olmasından dolayı, hasta geliş sıklık tahminlerinin günlük olarak kullanılması, kaynakların planlanması açısından yetersiz olacağından, saatlik olarak da hasta geliş sıklığı tahmini yapılmıştır. 1 yıllık veri ile, 2017 yılı için 8760 adetlik detaylı bilgiler ile saatlik tahmin yapılmıştır. Sonuçlar, Çizelge 4.2.'de gösterilmiştir. Bu tablo incelendiğinde en iyi sonucu rasgele ağaç algoritmasının verdiği görülmüştür.

Çizelge 4.2. 1 yıllık veri ile 10 farklı makine algoritmasının 10 katlamalı çapraz doğrulama yöntemiyle elde edilen saatlik hasta geliş sıklığı tahmin verilerinin OMYH istatistik sonuçları

MKÖ	LSTM	DR	KA	GA	SA	AB	K- EYK	DVM	ÇKA	RO
Ortalama	49,78	57,02	49,81	50,27	56,92	59,90	49,96	60,27	50,89	49,67
SS	5,64	2,14	2,45	4,14	2,20	2,68	2,30	2,57	3,09	2,45
En Küçük	42,27	52,63	46,21	45,06	52,55	55,79	45,48	54,51	46,23	46,12
En Büyük	57,46	61,34	55,68	56,14	61,31	65,09	55,00	64,96	58,38	55,58

SS : standart sapma

Tahmin keskinliğini arttırmak için veri kümesini büyütmek faydalı olabileceğinden, 1 yıllık veri yerine 5 yıllık veri ile aynı tahminler yapılmıştır. Bu amaçla 2013-2017 yılları arasındaki veriler derlenmiştir. 5 yıllık verinin kullanılmasından sonra, 1 yıllık veriye göre tahmin keskinliğinin %5,9 oranında iyileştiği tespit edilmiştir. 5 yıllık veri ile ilgili sonuçlar Çizelge 4.3.'de gösterilmiştir.

Çizelge 4.3. 5 yıllık veri ile 10 farklı makine algoritmasının 10 katlamalı çapraz doğrulama yöntemiyle elde edilen saatlik hasta geliş sıklığı tahmin verilerinin OMYH istatistik sonuçları

MKÖ	LSTM	DR	KA	GA	SA	AB	K- EYK	DVM	ÇKA	RO
Ortalama	46,73	59,21	50,77	52,68	59,08	79,12	52,19	96,17	52,12	50,78
SS	2,19	0,59	0,51	0,53	0,63	3,14	0,73	1,28	1,44	0,52
En Küçük	42,99	58,18	50,00	51,61	58,04	71,14	51,06	94,31	50,08	49,99
En Büyük	51,42	60,09	51,45	53,49	60,06	82,62	53,47	98,87	54,31	51,40


SS : standart sapma

İdeal öznitelik kümeleri kullanılarak her bir algoritma çalıştırılmış ve ortalama mutlak hata payı hesaplanarak makine öğrenme algoritmalarının


performansları hesaplanmıştır. Karar ağacı, çok katmanlı algılayıcılar ve LSTM en iyi sonucu verirken, Destek vektör makine, Poisson ve DR en kötü sonuçları vermiştir. Saatlik bazda yapılan tahminde en iyi sonuç Çizelge 4.3.'de gösterildiği gibi LSTM metodu ile sağlanmıştır.

Tahmin sonuçları incelendiğinde tahmin edilen zaman diliminin küçüldükçe, tahmin keskinliğinin de azaldığı gözlemlenmiştir. Planlamanın iyi gerçekleştirilebilmesi için tahmin kesinliği yüksek olmasına rağmen günlük tahminler tercih edilmemiştir.

Şekil 4.2'de 1 yıllık veri ile günlük tahminler bulunmaktadır. DVM sınıflandırma için kullanıldığından, tahmin performansının kötü olması normal karşılanabilirken, Poisson dağılımının sonuçlarının kötü olması beklenmeyen bir durumdur. Ortalama geliş sıklığının Poisson dağılımdan iyi sonuç vermesi beklenmedik bir olaydır. Özellikle literatürde Poisson dağılımı hasta geliş sıklığı gibi problemlerde çok fazla kullanılmaktadır. En yakın k komşuluğu algoritması da gradyan artırım kadar iyi sonuç vermiştir. En yakın k komşuluğu algoritması ise genelde sınıflandırma amaçlı kullanılmasına rağmen bir boosting algoritması kadar iyi sonuç verebilmiştir. LSTM'den alınan sonuç literatürdeki en iyi sonuçtur. Yalnız, bu modelin çok iyi olmasından değil, veri yapısından kaynaklanma ihtimali oldukça yüksektir. Yapay sinir ağları ile yapılan bir çalışmayı etkileyen çok fazla parametre olmasından dolayı, sonuca bakıp model veya öznetelik kümesi hakkında kesin konuşulmamalıdır. Simülasyon modelinde en iyi sonucu alabilmek için LSTM modelinin tahminlerini kullanmamız gerektiği tespit edilmiştir. Hasta geliş sıklığının saatlik tahmininde gerçek veriler ile tahmin veriler arasındaki ilişki Şekil 4.3.'de gösterilmiştir.



Şekil 4.2. LSTM, Poisson, Ortalama Geliş Oranı ve Diğer 9 MKÖ Algoritmasının Tahmin OMYH Değerlerinin Karşılaştırılması




Şekil 4.3. LSTM ile Yapılan Çalışmada Gerçek Değer ile Tahmin Değerinin Karşılaştırılması

4.1.3. Simülasyon Modeli ile ilgili Bulgular

Simülasyon modelinin gerçek sistemin benzetmesi olabilmesi için sistemin analizi gerekir. Bu amaçla acil servis gözlemlenmiş ve bazı bulgulara ulaşılmıştır. Hastalar, acil servise ya ambulansla ya da kendi imkanları ile gelmektedir. Kendi imkanları ile gelen her hastanın kişisel bilgilerini giriş hemşiresi kaydetmekte ve hastanın acil önem sırasını belirlemektedir. Bu acil önem sırasında, hastanede kırmızı, sarı ve yeşil kategorileri bulunmaktadır. En acil tedaviye ihtiyaç duyan hastalar kırmızı kategoriye giriyor, normal acil durumlar için sarı renk, en az acil durumdaki hastalar yeşil renk kategoriye giriyor. Acil önem sırası belirlendikten sonra, acil doktoru hastayı muayene ediyor ve gerekirse röntgen, laboratuvar bölümlerine sevk eder. Muayeneden sonra ya gözlem odasına, ya da gerekiyorsa hastayı muayene odasına gönderiyor. Uzman doktora gönderilen hasta muayeneden sonra ya tekrar laboratuvar, röntgen bölümlerine, ya da gözlem odasına gönderiliyor. Ambulansla gelen hasta için de giriş hemşiresi ile ilgili kısım hariç kırmızı katogoriye alınan hasta için aynı işlemler yapılır. Acil sistemdeki akışı daha iyi anlayabilmek için acil servisteki hasta akışını gösteren akış şeması Şekil 4.4’de gösterilmiştir. Bu şema aynı zamanda simülasyon modelinin Arena yazılımında tasarlanması için temel oluşturmuştur.

Simülasyon modeli için en önemli değişken tahmin edildikten sonra gerçek sistemle tamamen uyumlu bir simülasyon modelinin tasarlanması için diğer değişkenlerin gerçeğe uygun şekilde tespit edilmesi gerekmiştir. Acil servislerde hastaların hastalıklara bağlı olarak gördükleri tedavi işlem süresi ve hastaların acil servise giriş yaptıktan sonra hangi rotayı takip ettikleri ve yüzde kaçının hangi rotaya gittiğinin bilinmesi gerekmektedir. Bunun için hastanede gözlemler yapılmış olup, hastane yönetiminden ve çalışanlarından konuyla ilgili bilgi alınmıştır. Veri analizi yaparak rotaların yüzdesi oluşturulmuştur.



Şekil 4.4. Acil Servis Hasta Akış Şeması


Acil servise gelenlerin %70 kadarı röntgen ve laboratuvar bölümüne sevk edilmektedir. Acil servise gelenlerin yaklaşık yarısı da uzman doktora yönlendirilmektedir. %22 kadarı çocuk doktoruna, %17'si kulak burun boğaz doktoruna, %13'ü iç hastalıklar uzmanına, %11 kadarı ortopedi ve travmatoloji uzmanına ve kalan hastalarda yaklaşık 10 farklı dalda uzman doktora yönlendirilmektedir. Tedaviden sonra her hasta gözlem odasına gitmektedir. Simülasyon modelinde, hastanın hangi tedavi işleminde ne kadar süre geçireceğini modele girdi olarak verilir ve model de gerçeğe uygun çalıştırılır. Her bölüm için tedavi süreleri Çizelge 4.4.'de gösterilmiştir. Bu tedavi süreler (Yousefi ve ark, 2018) çalışmasında ki süreler gibi olasılık dağılımları ile gösterilmiş ve hastane koordinatörü tarafından onaylanmıştır.

Çizelge 4.4. Acil Serviste Tedavi Süreleri

Süreç	Dağılım Fonksiyonları	Kaynak	Referans
Triaj Odası	UNIF(2,4)	Hemşire	Uzman Görüşü
AS Doktor Muayenesi	TRIA(5,8,15)	AS Doktoru	Uzman Görüşü
Lab. & Röntgen	TRIA(15,30,45)	Laborant	Uzman Görüşü
Uzman Doktor Muayenesi	TRIA(5,10,15)	Uzman Doktor	Uzman Görüşü
Gözlem Odası	TRIA(30,60,120)	Yatak	Uzman Görüşü
Hasta Gözlem Odası	TRIA(30,60,120)	Uzman Doktor	Uzman Görüşü
Çocuk Doktoru	TRIA(15,20,40)	Uzman Doktor	Uzman Görüşü
Kulak Burun Boğaz	TRIA(5,8,20)	Uzman Doktor	Uzman Görüşü
İç Hastalıkları Uzmanı	TRIA(15,20,30)	Uzman Doktor	Uzman Görüşü
Ortopedi ve travmatoloji uzmanı	TRIA(5,10,20)	Uzman Doktor	Uzman Görüşü

Simülasyon modelinin oluşturulması ve sağlıklı sonuçlar alınabilmesi için, akış şeması, tedavi süreleri ve hastaların gideceği rota yüzleri gibi modelin replikasyon sayısının belirlenmesi gerekmektedir. Bu çalışmada sıralı yöntem kullanılmış olup, replikasyon sayısı 5 bulunmuştur. Simülasyon modellerinde kararlı hale ulaşmak için Welch grafik metodu kullanılmıştır. Bu modelde zaman

aralığı 1 birim kabul edilerek, kararlı hale gelme süresi Şekil 4.5’da görüldüğü gibi 29 saat olarak tespit edilmiştir. Herhangi bir sapmayı engelleyebilmek için, simülasyon modeli 7500 saat, 5 replikasyonla ve 10 farklı veri grubu ile çalıştırılmıştır.




Şekil 4.5. Welch Metoduyla Kararlı Hale Gelme Süresi Grafiği

4.1.4. Simülasyon Modeli İle Kaynak Planlaması


Acil servislerde en önemli performans kriterlerinden biri olan hasta kalış süresi ile yatak sayısının ilişkisi incelenmiş, yatak sayısı da buna göre planlanmak istenmiştir. Yatak sayısını arttırdıkça hasta bekleme süresinin belli bir noktaya kadar azaldığı fakat daha sonra ise yatak sayısının artmasının hasta bekleme süresine bir katkısı olmadığı gözlemlenmiştir. Şekil 4.6.’de görüldüğü gibi 10 adet yataktan fazlasının bekleme süresinin kısalmasına katkısı bulunmamaktadır. Diğer kaynakların da yatak sayısına göre planlanması acil servisin tüm kaynak

planlamasının yapılmasına katkıda bulunacaktır. Bu çalışmada acil serviste hastanın kalış süresi, hastanın acil servise gelmesinden hastaneyi terk edene kadar olan süre olarak kabul edilmiştir.



Şekil 4.6. Yatak Sayısı ile Yatak Bekleme Süresi Arasındaki İlişki

Şekil 4.7’de yatak sayısı ile yatak bekleme süresi arasındaki ilişkiyi göstermektedir. Yatak sayısının artması ile yatak sırasında bekleme süresi de azalmaktadır. Bu doğru orantı yakın bir ilişkidir. Bu da acil önem sırasının acil servis birimlerinde ne kadar önemli olduğunu göstermektedir. Kırmızı kodlu hastanın çok gelmesi diğer hastaların bekleme süresini çok fazla arttırmaktadır.



Şekil 4.7. Yatak Sayısı ile Yatak Sırası Arasındaki İlişki

5. SONUÇLAR VE ÖNERİLER**5.1. Sonuçlar**

Genel olarak tahminlerin keskinliğine katkıda bulunabilmesi için genel olarak basit bilgiler veya korelasyon analizinden faydalanılarak bu katkıyı yapabilecek değişkenler seçilir. Bu çalışmada korelasyon analizi veya diğer öznitelik seçim kuralları kullanılmadan kapsamlı öznitelik seçim yönteminden faydalanılarak, ideal öznitelik kümesi belirlendi. Şekil 4.1.'de gösterildiği gibi nem ve sıcaklık hasta geliş sıklığı ile ilişkili olduğu tatil ve mevsimlerin ise daha az ilişkili olduğu görülmektedir. Buna karşılık, örneğin saatlik hasta geliş tahmini için, saatlik tahminde hafta içi günlerinin, mevsim ve tatillerin tahmin keskinliğine katkısı bulunduğu, nem ve sıcaklığın ise dikkate alınmadığı görülmüştür. Günlük tahminlere katkısı bulunan değişkenleri incelediğimizde tatil günlerinin, mevsimlerin, haftanın hangi günü olduğunun, az da olsa nem ve sıcaklığında etkisi olduğu görülmüştür. Bunlarda bize ideal öznitelik kümesinin asıl belirleyicisinin algoritmaya verilen veri yapısı olduğunu, tahmin edilecek hedef bilgi ile değişkenlerin korelasyonun önemsiz olduğunu göstermiştir. Bu sebeple, kapsamlı öznitelik seçim yöntemi hariç diğer yöntemler etkisi az öznitelik kümesi oluşturmaya sebep verebilir. Her bir öznitelik hedef veriyi tahmin etmek için anlamlı olurken, kombinasyonları anlamsız sonuçlar verebilir ve tahmin başarısını azaltabilir. Öznitelik seçimi bize daha küçük bir öznitelik kümesi ile çalışma olanağı verir. Öznitelik kümesi ile yapılan optimizasyon sonuçlara çok daha hızlı ulaşmamıza ve modelin daha sade olmasını sağlar. Modelin sadeliği ise bize ayrı bir avantaj sağlar. Ayrıca bu çalışmada belirlenen öznitelik kümesi, başka hiçbir veriyi tahmin etmeden hasta geliş sıklığını tahmin etmemize olanak verir. Örneğin, eğer hava durumu verilerine ihtiyaç duyulsaydı, geleceği tahmin etmek için gelecekteki hava durumunu da tahmin etmek gerekecekti. Bazı çalışmalarda, saatlik hasta gelişlerinde, hastanın geldiği saatin çok önemli bir öznitelik olduğu ifade edilir (Carvoilla ve ark, 2018). Yalnız ortalama geliş sıklığı saatlik geliş

sıklığından daha önemli olmuştur. Öznitelik kümesine ortalama saatlik geliş sıklığını eklenince, öznitelik seçim yöntemi gün içi saat özniteliğini ideal öznitelik kümesinden çıkarmıştır. Bu özniteliğin bir başka avantajı da sürekli kendini güncelleyecek olup, hasta geliş sıklığındaki değişimler bu özniteliğe yansiyacaktır. Sonuçlar, hava durumu bilgisinin hasta geliş sıklığını etkilemediğini göstermektedir. Bunun sebebi bölgemizde ağır hava şartları olmaması olabilir. Bu bilginin geçerliliğini test etmek için ağır hava şartlarının olduğu bir bölgede bu çalışmanın yapılması gerekir. Bazı çalışmalar pazartesisinin hasta yoğunluğu açısından en yoğun gün olduğunu ifade etmektedir. Bazıları da hafta sonu hasta yoğunluğunun azaldığını belirtmektedirler. Bu çalışmada hafta içi her gün hasta yoğunluğunun birbirine yakın olduğunu ve diğer çalışmaların aksine hafta sonu da hasta yoğunluğunun %50 arttığı görülür. Tüm bunlar özniteliklerin etkisinin bölgeden bölgeye ve kültüre göre değişebileceğini göstermektedir.

Bu çalışmada, acil servis için hasta geliş sıklığı tahmin edilirken hem 1 yıllık hem de 5 yıllık saatlik veri kullanılmıştır. Bu büyüklükte ki bir veri kümesi ile saatlik tahmin çalışması literatürde bulunmamaktadır. 5 yıllık verinin kullanılması, bu çalışmanın başka bir güçlü yönüdür. Yıllara ait bir veri kümesi daha keskin tahmin yapmamızı ve mevsimsel sapmalar gibi bazı etkileri yok etmemizi de sağlar. Ayrıca, ortalama geliş oranını da çok daha iyi tahmin etmemizi sağlar. Veri kümesinin karmaşıklığı arttıkça, LSTM modeli diğer makine öğrenme algoritmalarından daha başarılı sonuçlar verdiği gözlenmiştir. Acil servisi saat bazında incelediğimizde bazı saatlerde, özellikle akşam 8 ve 11 arasında çok yoğun olduğu görülür ve sabah 4 ile 6 arasında ise saatte bir veya iki hasta gelmektedir. Bu sebeple, AS yöneticilerinin kalabalık problemini incelerken ve kaynak planlaması yapacakları zaman saat bazında planlamaları çok daha doğru sonuç verebilecektir.

Tekrarlayan sinir ağıları modeli tasarlanırken birçok parametre seçilmektedir. Deneme ve yanılma yöntemi ile, farklı sayıda gizli nöronlar, öğrenme oranı ve aktivasyon fonksiyonları test edildi. Bu ve diğer parametrelerde

ince ayarlar yapılarak tahmin başarısı yükseltilmeye çalışıldı. Literatürdeki en başarılı sonuç elde edilmiş de olsa, bu tasarımın başarısı olmayabilir. Çünkü yapay sinir ağlarında hangi mimarinin en iyi olduğunu bilmek imkansızdır. Bu başarılı sonucun sebebi veri yapısı olabilir. Çizelge 4.2’de görüldüğü gibi rasgele orman bir yıllık veri için en başarılı sonucu verirken, 5 yıllık veri ile çalışıldığında Çizelge 4.3 ‘de görüldüğü gibi 3. en iyi sonucu vermektedir.

Bir çok çalışmada, yatak doluluğunun %90 oranını geçtiğinde AS’lerde bekleme süresinin de arttığını, boş yatak sayısı ile tedavi bekleyen hasta sayısı arasında negatif korelasyon olduğunu ifade etmektedirler (Kortbeek, 2014). Simülasyon modelleriyle yatak sayısı ile aşırı kalabalık problemi rahatlıkla incelenebilir. Bu çalışmada da yatak sayısı 7’den 10’a yükseldikçe acil serviste hasta kalış süresi azalmaktadır. 10 yatak sayısına ulaşıncaya, yeni bir yatak adedin eklenmesi ise hasta kalış süresinde azalmaya sebep vermemektedir. Doktor ve hemşire sayısının kısıtlı olması yatak sayısının artmasına rağmen hasta kalış süresinin azalmasına engel olmaktadır. Hasta kalış süresini azaltmak için doktor sayısının artırılması gerekmektedir.

5.2. Öneriler

Bu çalışmada simülasyonun gerçek sisteme olabildiğince benzemesi için hasta geliş sıklığı değişkeni yapay sinir ağları ve diğer makine öğrenmeleri algoritmaları ile tahmin edilmiştir. Simülasyonun daha iyi gerçek sistemi modelleyebilmesi için hasta bekleme süresinin de makine öğrenme algoritmaları ile tahmin edilmesi gerekir. Bu çalışmanın en önemli sınırlamalarından biri HBS verilerine ulaşamamış olmasıdır. Araştırmacılar gelecek çalışmalarında daha başarılı sonuçlara ulaşmak için bu eksiğin üstesinden gelmelidir, ayrıca aşağıdaki önerileri de göz önünde bulundurabilir:

- Simülasyon yöntemi ile yatak sayılarını arttırarak bir noktaya kadar aşırı kalabalık problemini azaltılabilir. Ama problemin tamamen

çözümü için diğer kaynaklara da odaklanmak gerekir. Tüm kaynakları aynı anda optimize etmek daha doğru bir kaynak planlamasının yapılmasını sağlayacaktır.

- Hastane yönetimi genelde kaynak planlaması konusuna çok fazla vakit ayıramamakta ve konuyu çok zor bulmaktadır. Simülasyon modeli ve yapay zeka destekleri ile karar destek sistemleri hastane yönetimine faydalı olmak amacıyla yapılabilir.
- Bu çalışmada kullanılan makine öğrenme algoritmalarının çıktılarının simülasyon modeline girdi olarak kullanma yöntemi diğer sağlık servisleri ile ilgili problemlere de uygulanabilir.
- Bu çalışmada sunulan çözüm, hastanelere kolayca uygulanabilir. Çünkü, hesaplama zamanı çok kısa olup, iyileştirme konusunda oldukça başarılı ve hastane çalışanları tarafından kolayca kullanabilecekleri bir çözümdür. Bu yöntem, hastaneler yönetim bilişim sistemlerine entegre edilerek, kaynak planlaması yapmak için kullanılabilir.
- Öznitelik kümesinin seçimi çok önemli olduğundan, hesaplama zamanı uygun olan problemlerde de mutlaka kapsamlı öznitelik seçim yöntemi kullanılırsa tahmin başarısı artabilir.
- Literatürde birçok çalışma $\lambda(t)$ oranına sahip, homojen olmayan Poisson dağılımı kullanır. Bu çalışma ise ortalama geliş oranının bu dağılımdan çok daha iyi sonuç verdiğini gösterdiğinden, Poisson dağılımı kullanılmadan önce ortalama geliş oranı ile karşılaştırılmalıdır.
- Bu çalışmada 10 adet makine öğrenme algoritması kullanılmış ve makine öğrenme algoritmalarının başarılarının veri yapısının içeriğine ve boyutuna bağlı olarak tahmin başarılarının değiştiği gözlemlenmiştir. Bu sebeple, makine öğrenme çalışmalarında, bir çok farklı makine öğrenme algoritmaları kullanılması çalışmaların başarısını artırır.

KAYNAKLAR

- Abraham, G., Byrnes, G.B., Bain, C.A., 2009. Short-Term Forecasting of Emergency Inpatient Flow. *IEEE Transactions on Information Technology in Biomedicine*, 13(3).
- Adıyaman, F., 2007. Talep Tahmininde Yapay Sinir Ağlarının Kullanılması. (Yayınlanmamış).
- Ahmed, M.A., Alkhamis, T.M., 2009. Simulation Optimization For an Emergency Department Healthcare Unit in Kuwait. *European Journal of Operational Research*, 198:936–942.
- Alpaydın, E., 2004. Introduction to Machine Learning. Massachusetts Institute of Technology, London, 415s.
- _____, 2013. Yapay Öğrenme. Boğaziçi Üniversitesi Yayınevi, İstanbul, 486s.
- Asplin, B.R., Magid, D.J., Rhodes. K.V. et al. 2003. A Conceptual Model of Emergency Department Crowding. *Annals of Emergency Medicine*, 42:173-180.
- Baxt, W.G., Shofer, F.S., Sites, F.D., Hollander, J.E., 2002. A Neural Network aid for the Early Diagnosis of Cardiac Ischemia in Patients Presenting to the Emergency Department with Chest Pain. *Annals of Emergency Medicine*, 40(6): 584-595.
- Bayır, F., 2006. Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama. (Yayınlanmamış).
- Bergs, J., Heerinckx, P., Verelst, S., 2014. Knowing What to Expect, Forecasting Monthly Emergency Department Visits: A Time-Series Analysis. *International Emergency Nursing*, 22:112–115.
- Bezděk, V., 2014. Using fuzzy Logic in Business. *Procedia-Social and Behavioral Sciences*, 124:371-380.

- Blum, A.L., Langley, P., 1997. Selection of Relevant Features and Examples in Machine Learning. *Artificial Intelligence*, 97:245-271.
- Bonnabel, S., 2013. Stochastic Gradient Descent on Riemannian Manifolds. *IEEE Transactions on Automatic Control*, 58(9).
- Boyle, J., Jessup, M., Crilly, J. et al. 2011. Predicting Emergency Department Admissions. *EMJ*, 1-8.
- Brailsford, S., 2014. Discrete-Event Simulation is Alive and Kicking. *Journal of Simulation*, 8:1-8.
- Budak, H., 2018. Özellik Seçim Yöntemleri ve Yeni Bir Yaklaşım. *Journal of Natural and Applied Sciences*.
- Carvalho-Silva, M., Monteiro, M.T.T., Sá-Soares, F., Dória-Nóbrega, S., 2018. Assessment of Forecasting Models for Patients Arrival at Emergency Department. *Operations Research for Health Care*, 18:112-118.
- Cristianini, N., Shawe-Taylor, J., 2004. *Support Vector Machines*. Cambridge University Press, United Kingdom, 189s.
- Connelly, L.G., Bair, A.E., 2004. Discrete Event Simulation of Emergency Department Activity: A Platform for System-level Operations Research. *Acad. Emerg. Med.*, 11(11).
- Cura, T., 2008. Doğrusal Olmayan Küresel Optimizasyon Problemleri İçin Tabu Arama Algoritmasının Kullanılması. *Istanbul University Journal of the School of Business Administration*, 37(1):22-38.
- Davis, B.H., McLaren, C.E., Carcioetal., A.J., 2013. Determination of Optimal Replicate Number for Validation of Imprecision Using Fluorescence Cell-based Assays: Proposed practical method, *Cytometry Part B (ClinicalCytometry)*, 84(5):329–337.
- Erdem, F., Derinpınar, M.A., Nasirzadehdizaji, R., et al. 2018. Rastgele Orman Yöntemi Kullanılarak Kıyı Çizgisi Çıkarımı İstanbul Örneği. *Journal of Geomatics*, 3(2):100-107.

- Gholipour, C., Rahim, F., Fakhree, A., behrad Ziapour, B., 2015. Using an Artificial Neural Networks (ANNs) Model for Prediction of Intensive Care Unit (ICU) Outcome and Length of Stay at Hospital in Traumatic Patients. *Internal Medicine Section*, 9(4):19-23.
- Golmohammadi, D., 2016. Predicting Hospital Admissions To Reduce Emergency Department Boarding. *Int. J. Production Economics*, 182:535–544.
- Graham, B., Bond, R., Quinn, M., Mulvenna, M., 2018. Using Data Mining to Predict Hospital Admissions From the Emergency Department. *IEEE*, 6.
- Guyon, I., Elisseeff, A., 2003. An Introduction to Variable and Feature Selection. *Journal of Machine Learning Research*, 3:1157-1182.
- Gül, M., Güneri, A.F., 2012. A Computer Simulation Model to Reduce Patient Length of Stay and to Improve Resource Utilization Rate in an Emergency Department Service System. *International Journal of Industrial Engineering*, 19(5):221-231.
- _____, 2015. Forecasting Patient Length of Stay in Emergency Department by Artificial Neural Networks. *Journal of Aeronautics and Space Technologies*, 8(2):43-48.
- _____, 2015. A Comprehensive Review of Emergency Department Simulation Applications for Normal and Disaster Conditions. *Computers & Industrial Engineering*.
- Gürsaka1, N., 2017. *Makine Öğrenme ve Derin Öğrenme*. Ezgi Matbaacılık, Bursa, 309s.
- Haldurai, L., Madhubala, T., Rajalakshmi, R., 2016. A Study on Genetic Algorithm and its Applications. *Internatinal Journal of Computer Sciences And Engineering*, 4(10).
- Hall, M.A., Smith, L.A., 1999. Feature Selection for Machine Learning: Comparing a Correlation-based Filter Approach to the Wrapper. *Proceedings of the Twelfth International FLAIRS Conference*.

- Hedar, A.R., Fukushima, M., 2004. Tabu Search Directed by Direct Search Methods for Nonlinear Global Optimization. Elsevier Science.
- Hertzum, M., 2018. Forecasting Hourly Patient Visits in the Emergency Department to Counteract Crowding. The Ergonomics Open Journal, 11.
- Hong, W.S., Haimovich, A.D., Taylor, R.A., 2018. Predicting Hospital Admission at Emergency Department Triage Using Machine Learning. Plos One, 13(7).
- Hu, W., Hu, W., Maybank, S., 2008. AdaBoost-Based Algorithm for Network Intrusion Detection. IEEE Transactions On Systems, 38(2).
- İşçi, Ö., Korukoğlu, S., 2003. Genetik Algoritma Yaklaşımı ve Yöneylem Araştırmasında Bir Uygulama. Yönetim ve Ekonomi, 10(2):191-208.
- Jones, A., Costa, A.P., Pesevski, A., McNicholas, P.D., 2018. Predicting Hospital and Emergency Department Utilization Among Communitydwelling Older Adults: Statistical and Machine Learning Approaches. Plos One, 13(11).
- Jones, S.S., Thomas, A., Evans, R.S. et al. 2008. Forecasting Daily Patient Volumes in the Emergency Department. The Society for Academic Emergency Medicine, 15:159–170.
- Kabir, M., Islam, M., Murase, K., 2008. A New Wrapper Feature Selection Approach Using Neural Network. Department of Human and Artificial Intelligence Systems.
- Kadı, D., Kuvvetli, Y., Çolak, S., 2016. Performance Analysis of a University Hospital Blood Laboratory via Discrete Event Simulation. Simulation, 92(5):473–484.
- Kamacı, A., 2017. OECD Ülkelerinde Sağlık Harcamalarının Ekonomik Büyüme Üzerindeki Etkisinin Ekonometrik Analizi. The Sakarya Journal of Economics, 6(2):52-69.

- Kaygın, C.Y., Tazegül, A., Yazarkan, H., 2016. İşletmelerin Finansal Başarılı ve Başarısız Olma Durumlarının Veri Madenciliği ve Lojistik Regresyon Analizi İle Tahmin Edilebilirliği. *Ege Akademik Bakış*, 16(1):147-159.
- Kelton, W.D., Sadowski, R.P., Sturrock, D.T., 2004. *Simulation with Arena*. McGraw-hill, Boston, 630s.
- Kempter, R., Gerstner, W., Hemmen, J.L., 1999. Hebbian Learning and Spiking Neurons. *The American Physical Society*, 59(4).
- Kiusalaas, J., 2005. *Numerical Methods in Engineering with Python*. Cambridge University Press, USA, 424s.
- Komashie, A., Mousavi, A., 2005. Modeling Emergency Departments Using Discrete Event Simulation Techniques. *Proceedings of the 2005 Winter Simulation Conference*.
- Kortbeek, N., Braaksma, A., Smeenk, H.F., Bakker, P.J. M., 2014. Integral Resource Capacity Planning for Inpatient Care Services Based on Hourly Bed Census Predictions. *Journal of the Operational Research Society*, 66(7).
- Kortbeek, N., Braaksma, A., Burger, C.A.J., Bakker, P.J.M., Boucherie, R.J., 2015. Flexible Nurse Staffing Based on Hourly Bed Census Predictions. *Int. J. Production Economics*, 161:167-180.
- Law, A.M., 2007. *Simulation Modeling and Analysis*, McGraw-Hill, Boston, 768s.
- Lee, S., Jeong, T., 2017. Forecasting Purpose Data Analysis and Methodology Comparison of Neural Model Perspective. *Symmetry*, 9(108):1-11.
- Liebowitz, J., 1995. Expert Systems: A Short Introduction. *Engineering Fracture Mechanics*, 50(6):601-607.
- Lucini, F.R., Fogliatto, S.F., Silveira, G.J.C. et al. 2017. Text Mining Approach To Predict Hospital Admissions Using Early Medical Records From The Emergency Department. *International Journal of Medical Informatics*, 100:1-8.

- Lutz, M., Ascber, D., 2003. Learning Python. O'reilly, USA, 591s.
- Maidstone, R., 2012. Discrete Event Simulation. System Dynamics and Agent Based Simulation: Discussion and Comparison, ResearchGate.
- Marko, D., Karba, R., Zupancic, B., 1992. Simulation and Modelling of Continuous Systems. Hall International, UK, 312s.
- Mazgit, İ., 2002. Bilgi Toplumu ve Sağlığın Artan Önemi, 1. Ulusal bilgi, Ekonomi ve Yönetim Kongresi.
- McCarthy, L.M., Zeger, S.L., Ding, R., et al. 2008. The Challenge of Predicting Demand for Emergency Department Services. The Society for Academic Emergency Medicine, 15:337–346
- Moralı, İ.A., 2007. Aygün, F.F., Çok Katmanlı Algılayıcı ve Geriye Yayılım Algoritması ile Konuşmacı Ayırt Etme. Akademik Bilişim'07 - IX. Akademik Bilişim Konferansı Bildirileri, Dumlupınar Üniversitesi, Kütahya.
- Natekin, A., Knoll, A., 2013. Gradient Boosting Machines, a Tutorial. Frontiers in Neurorobotics.
- Olshaker, J.S., Rathlev, N.K., 2006. Emergency Department Overcrowding and Ambulance Diversion: the Impact and Potential Solutions of Extended Boarding of Admitted Patients in the Emergency Department. The Journal of Emergency Medicine, 30(3).
- Onan, A., Korukoğlu, S., 2016. A Review of Literature on the Use of Machine Learning Methods for Opinion Mining. Pamukkale Üniversitesi Muh. Bilim Dergisi, 22(2):111-122.
- Öztemel, E., 2012. Yapay Sinir Ağları. Papatya Yayıncılık Eğitim, İstanbul, 232s.
- Parker, C.A., Liu, N., Wu, S.X. et al. 2019. Predicting Hospital Admission at the Emergency Department Triage: A Novel Prediction Model. American Journal of Emergency Medicine, 37(8): 1498-1504.

- Paul, J.A., Lin, L., 2012. Models for Improving Patient Throughput And Waiting at Hospital Emergency Departments. *Administration of Emergency Medicine*, 43(6):1119-1126.
- Pedro, H., Coimbra, C., 2015. Nearest-Neighbor Methodology for Prediction of Intra-hour Global Horizontal and Direct Normal Irradiances. *Renewable Energy* 80:770-782.
- Pirim, H., 2006. Yapay Zeka. *Journal of Yasar University*, 1(1): 81-93.
- Rajendran, C., Ziegler, H., 2004. Ant-colony Algorithms for Permutation Flowshop Scheduling to Minimize Makespan/Total Flowtime of Jobs. *European Journal of Operation Research*, 155(2):426-438.
- Ramaswami, M., Bhaskaran, R., 2009. A Study on Feature Selection Techniques in Educational Data Mining. *Journal of Computing*, 1(1).
- Rodriguez-Galiano, V., Sanchez-Castillo, M., Chica-Olmoc, M., Chica-Rivas, M., 2015. Machine Learning Predictive Models for Mineral Prospectivity: an Evaluation of Neural Networks, Random Forest, Regression Trees and Support Vector Machines. *Ore Geology Reviews*, 71:804–818
- Sağıroğlu, Ş., Beşdok, E., Erler, M., 2003. Mühendislikte Yapay Zeka Uygulamaları I. *Ufuk Yayıncılık, Kayseri*, 426s.
- Schiavoa, M.L., Prinari, B., Gronski, J.A., Serio, A.V., 2015. An Artificial Neural Network Approach for Modeling the Ward Atmosphere in a Medical Unit. *Mathematics and Computers in Simulation*, 116:44-58.
- Kilmer, R.A., Smith, A., Shuman, L.J., 1997. An Emergency Department Simulation and a Neural Network Metamodel. *Journal of the Society for Health Systems*.
- Stewart, J., Sprivulis, P., Dwivedi, G., 2018. Artificial Intelligence and Machine Learning in Emergency Medicine. *Emergency Medicine Australasia*, 30:870–874

- Sun, Y., Heng, B.H., Seow, Y.T., Eillyne Seow, E., 2009. Forecasting Daily Attendances at an Emergency Department to Aid Resource Planning. BMC Emergency Medicine, 9:1
- Taban, S., 2006. Türkiye’de Sağlık ve Ekonomik Büyüme Arasındaki Nedensellik İlişkisi. Sosyo Ekonomik.
- Wargon, M., B Guidet, B., Hoang, T.D., Hejblum, G., 2009. A Systematic Review of Models for Forecasting the Number of Emergency Department Visits. EMJ, 26:395–399
- Woolfson, M.M., Pert, G.J., 1999. An Introduction to Computer Simulation. Oxford University, New York, 311s.
- Xu, M., Wong, T.C., Chin, K.s., 2013. Modeling Daily Patient Arrivals at Emergency Department and Quantifying the Relative Importance of Contributing Variables Using Artificial Neural Network. Decision Support Systems, 54(3):1488-1498.
- Yiğit, V., 2011. Genetik Algoritma ile Türkiye Net Elektrik Enerjisi Tüketiminin 2020 Yılına Kadar Tahmini. International Journal of Engineering Research and Development, 3(2).
- Yousefi, M., yousefi, M., Ferreria, R.P.M., Kim, J.H., Fogliatto, F.S., 2018. Chaotic Genetic Algorithm and Adaboost Ensemble Metamodeling Approach for Optimum Resource Planning in Emergency Departments. Artificial Intelligence in Medicine, 84:23-33.

ÖZGEÇMİŞ

1995 yılında Pamukbank ile iş hayatına başlamış ve yaklaşık 10 yıl süreyle BOSSA firmasında önce Planlama ve sonrasında Fason Hizmetler Şefi olarak çalışmıştır. Daha sonra 4 yıl süreyle Karsan Otomotiv Fabrikasında Kalite Kontrol, Lojistik ve Planlama bölümlerinde yönetici olarak görev yapmıştır. 2011 yılından itibaren ise, profesyonel olarak Finansal Enstrümanlar ve Portföy Yönetim Danışmanlığı yapmaktadır. Aynı zamanda Çukurova Üniversitesi Endüstri Mühendisliği Anabilim Dalında Doktora çalışmalarına devam etmektedir ve endüstri mühendisliği bölümünde lisans düzeyinde Finansal Piyasalar dersini 3 yıl boyunca vermiştir. Çukurova Teknokent bölgesinde faaliyet gösteren Küresis Ar-Ge Mühendislik Finans Eğitim ve Yazılım Hizmetleri Ltd. Firmasının kurucu ortağı olup, farklı sektörlerden sanayi ve hizmet kuruluşlarında Yönetim ve Finans Danışmanlığı faaliyetlerini yürütmüştür. 2018 yılından itibaren Küresis Finansal Danışmanlık ve Mühendislik Hizmetleri adı altında aynı konuda faaliyetlerini yürütmektedir. Portföy yönetimi, simülasyon modellemesi, yapay zeka yazılımı, entegre üretim planlaması, optimizasyon, lojistik yönetimi konularında çalışmalarına devam etmektedir.