



T.C.
PAMUKKALE ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

HEMŞİRELİK ANABİLİM DALI
DOĞUM-KADIN HASTALIKLARI HEMŞİRELİĞİ PROGRAMI
YÜKSEK LİSANS TEZİ

JİNEKOLOJİK KANSER HASTALARINDA NANDA
HEMŞİRELİK TANILARININ MAKİNE ÖĞRENMESİ VE
VERİ MADENCİLİĞİ YÖNTEMİ İLE GELİŞTİRİLMESİ

Merve VİCİR

Ocak 2023
DENİZLİ

T.C.
PAMUKKALE ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

JİNEKOLOJİK KANSER HASTALARINDA NANDA
HEMŞİRELİK TANILARININ MAKİNE ÖĞRENMESİ VE VERİ
MADENCİLİĞİ YÖNTEMİ İLE GELİŞTİRİLMESİ

HEMŞİRELİK ANABİLİM DALI
DOĞUM-KADIN HASTALIKLARI HEMŞİRELİĞİ PROGRAMI
YÜKSEK LİSANS TEZİ

Merve VİCİR

Tez Danışmanı: Prof. Dr. Sevgi ÖZKAN

Denizli, 2013

Bu tezin tasarımı, hazırlanması, yürütülmesi, arařtırmalarının yapılması ve bulgularının analizlerinde bilimsel etięe ve akademik kurallara özenle riayet edildiđini; bu çalıřmanın doğrudan birincil ürünü olmayan bulguların, verilerin ve materyallerin bilimsel etięe uygun olarak kaynak gösterildiđini ve alıntı yapılan çalıřmalara atfedildiđini beyan ederim.

Öđrenci
Adı Soyadı : Merve VİCİR

İmza :

ÖZET

JİNEKOLOJİK KANSER HASTALARINDA NANDA HEMŞİRELİK TANILARININ MAKİNE ÖĞRENMESİ VE VERİ MADENCİLİĞİ YÖNTEMİ İLE GELİŞTİRİLMESİ

Merve VİCİR

Yüksek Lisans Tezi, Hemşirelik Anabilim Dalı
Doğum-Kadın Hastalıkları Hemşireliği Programı
Tez Yöneticisi: Prof. Dr. Sevgi ÖZKAN

Ocak 2023, 102 sayfa sayısı

Bu çalışmada, hemşireler için en önemli yol gösterici olan NANDA bakım planları içerisinde yer alan Jinekolojik hastalarda konulan hemşirelik tanılarının makine öğrenmesi ve veri madenciliği yöntemiyle geliştirilmesi amaçlanmıştır. Pamukkale Üniversitesi Hastanesinde 2015-2021 yılları arasında jinekonkolojik tanı alıp ameliyat olmuş veya olacak olan 304 hasta çalışmaya dahil edilmiştir. Hastaların kalış tarihleri preoperatif ve postoperatif dönemlere ayrılmıştır. Bu süreçte hastaya uygulanan kan testleri, hastanın hastaneye geliş şikayetleri, patoloji raporları, jinekonkolojik tanıları, kronik hastalıkları, yapılan ameliyat bilgileri veri otomasyon sisteminden alınmıştır. Verilerde hemşirelik tanılarını etkileyebilecek faktörler, ilgili literatüre dayalı olarak araştırılmıştır. Bu araştırmanın ardından girdi değişkenleri olarak entegre edilmek üzere hasta dosyalarından birincil ayırt edici faktörler seçilmiştir. Uygun yapay zeka programının seçilmesinin ardından verilere temizleme ve dönüştürme işlemleri yapılmıştır. En uygun algoritmanın belirlenmesi için denemeler yapılmış ve Multilayer Perceptron ve J48 yza veri tabanları seçilmiştir. Çalışmanın sonucunda 17 hemşirelik tanısı belirlenmiştir. Hemşirelik tanılarını etkileyen ilişkili veriler bulunmuştur. Bu tanıların doğruluk oranları ortalaması %98'dir. Eğitim verilmiş hemşirelerden verilerin toplanması gelecekte yapılacak çalışmalarda, makine öğrenimi ve veri madenciliği yöntemi için daha sağlıklı hemşirelik tanılarının ortaya çıkmasına neden olacaktır. Ayrıca bu yöntemle yapılan çalışmaların artması sonucu sağlık profesyonelleri sadece analiz edilen verilerle hastalarının tanı, tedavi ve bakımında aktif rol alabileceklerdir. Sağlık profesyonelleri teknolojik gelişmelerle ilgili yeni yöntemleri kullanmaları için teşvik edilmelidir.

Anahtar Kelimeler: NANDA hemşirelik tanısı, makine öğrenme, yapay zeka, veri madenciliği

ABSTRACT

DEVELOPMENT OF NANDA NURSING DIAGNOSES IN GYNECOLOGICAL CANCER PATIENTS VIA MACHINE LEARNING AND DATA MINING METHODS

Merve VİCİR

Master's Thesis, Department of Nursing
Obstetrics-Gynecology Nursing Program
Thesis Manager: Prof. Dr. Sevgi ÖZKAN

January 2023, 102 pages

This study was conducted to develop nursing diagnoses in gynecological patients, which are included in the NANDA care plans, which are the most important guides for nurses, by using machine learning and data mining methods. A total of 304 patients who had been diagnosed with a gyneco-oncological disorder in Pamukkale University Hospital between 2015 and 2021 and had undergone or had been scheduled for surgery were included in the study. The dates when patients stayed in the hospital were divided into preoperative and postoperative periods. Patients' blood tests done during this process, presenting complaints, pathology reports, gyneco-oncological diagnoses, chronic diseases, and surgery information were obtained from the hospital information management system. Factors that may affect nursing diagnoses in the data were investigated based on the relevant literature. Following this review, primary distinguishing factors were selected from patient files to be integrated as input variables. After the selection of appropriate artificial intelligence software, the data cleaning and transformation procedures were conducted. Necessary trials were performed to determine the most suitable algorithm, and Multilayer Perceptron and J48 yza databases were selected. As a result of the study, 17 nursing diagnoses were determined. Relevant data that affected nursing diagnoses were identified. The average accuracy rate of these diagnoses was 98%. The collection of data from educated nurses will lead to the emergence of healthier nursing diagnoses for machine learning and data mining methods in future studies. In addition, as a result of the increase in studies conducted with this method, health professionals will be able to take an active role in the diagnosis, treatment, and care of their patients only with the data analyzed. Health professionals should be encouraged to use new methods related to technological developments.

Keywords: NANDA nursing diagnosis, machine learning, artificial intelligence, data mining

TEŞEKKÜR

Yüksek lisans eğitimime başlamamda öncü olan, eğitimim boyunca yönlendirme ve bilgilendirmeleriyle seçimlerimi her zaman göz önünde bulundurarak bana yardımcı olan, bu çalışmanın planlanması ve yürütülmesinde bana destek olan, bilgi ve tavsiyelerini benimle paylaşan, her şeyi danışabildiğim, güler yüzünü ve sohbetini benden esirgemeyen, en önemlisi bana öğrenmeyi öğreten çok değerli danışman hocam **Prof. Dr. Sayın Sevgi ÖZKAN'a**,

Yapay zeka algoritmasının geliştirilmesinde destek veren değerli hocam **Öğr. Gör. Hüseyin TURGUT'a**

Yüksek lisans eğitimim boyunca bilgi ve tecrübelerini esirgemen akademik gelişmeye katkı sağlayan değerli hocam **Prof. Dr. Pınar Serçekuş Ak'a**

Yüksek lisans eğitimim boyunca bilgi ve tecrübelerini esirgemen akademik gelişmeye katkı sağlayan değerli hocam **Dr. Öğr. Üyesi Elif ULUDAĞ'a**

Tez savunma sınavı jürimde bulunan değerli hocam **Dr. Öğr. Üyesi Sayın Sibel ŞEKER'e**,

Hayatımın her aşamasında maddi-manevi destekleriyle hep yanımda ve arkamda olan, bugünlere gelmemde üzerimde büyük emeği olan iyi ki sizsiniz dediğim **sevgili aileme**

En içten saygı ve sevgilerimle teşekkürlerimi sunarım.

İÇİNDEKİLER

ÖZET	v
ABSTRACT	vi
TEŞEKKÜR	vii
İÇİNDEKİLER	viii
ŞEKİLLER DİZİNİ	x
TABLolar DİZİNİ	xii
SİMGELER VE KISALTMALAR DİZİNİ	v
1. GİRİŞ	1
1.1. Amaç.....	2
2. KURUMSAL BİLGİLER VE LİTERATÜR TARAMASI	3
2.1.Yapay Zeka.....	3
2.1.1. Sağlıkta Yapay Zeka	4
2.1.2. Kadın Sağlığında Yapay Zeka	6
2.1.3. Hemşirelikte Yapay Zeka	9
2.2.1. NANDA Tarihçesi	13
2.2.2. NANDA Kullanımı	13
3. GEREÇ VE YÖNTEMLER	15
3.1 Araştırmanın Tipi	15
3.2. Araştırmanın Yeri ve Zamanı	15
3.3. Araştırmanın Değişkenleri	15
3.4. Araştırmanın Evreni ve Örneklemi	16
3.4.1. Örneklem Özellikleri.....	16
3.5. Verilerin Elde Edilme Basamakları.....	17
3.6. Yapay Zekanın Geliştirilmesine Yönelik Uygulamalar.....	18

3.6.1. Yapay Zeka Algoritmasının İçeriği	18
3.6.2. Makine Öğrenimi Nedir?.....	19
3.6.3. Veri Madenciliği Nedir?.....	20
3.6.4. Yapay Zeka Nedir?.....	21
3.6.5. Yapay Sinir Ağları.....	22
3.7. Veri Toplama Aşaması	25
3.8. Araştırmanın Etik Yönü.....	26
3.9. Araştırmanın Sınırlılıkları	28
3.10. İstatiksel Analiz.....	29
3.10.1. Veri Toplama	29
3.10.2. Veri Tabanına Verilerin Kaydı.....	30
3.10.3. Veri Temizleme	31
3.10.4. Veri Dönüştürme.....	31
4.BULGULAR	35
4.1. Makine Öğrenmesi bulguları	35
4.2. Veri Madenciliği ve Karar Ağaçları Bulguları	54
5. TARTIŞMA	70
6. SONUÇ	73
KAYNAKLAR	75
8. ÖZGEÇMİŞ.....	84
9.EKLER	
EK-1. Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu	
EK-2.- Veri Talep Onayı	

ŞEKİLLER DİZİNİ

Şekil 3.1 Weka yazılımı ara yüzü	18
Şekil 3.2 Veri madenciliğinin aşamaları.....	20
Şekil 3.3 Veri madenciliği ve iş zekası.....	21
Şekil 3.4 Seçilmiş veri bilimi tekniklerinin şeması	22
Şekil 3.5 Biyolojik sinir hücre ve yapay sinir ağları yapısı	23
Şekil 3.6 Biyolojik sinir sistemi elemanları ve yapay sinir sisteminde karşılıkları.....	23
Şekil 3.7 Karar ağacı modeli	25
Şekil 3.8 Araştırmanın aşamaları	27
Şekil 3.9 Araştırma sürecinde yapılan çalışmaların zamana göre dağılımı	28
Şekil 3.10 Veri temizleme işlemi sonrası ve veri dönüştürülmesi sonrası durum....	33
Şekil 3.11 Verilerin Multilayer Perceptron örnek biçimi.....	34
Şekil 4.1 Banyo yapmada özbakım yetersizliği tanısına ilişkin karar ağacı	55
Şekil 4.2 Beslenmede özbakım yetersizliği tanısına ilişkin karar ağacı.....	56
Şekil 4.3 Tuvalet ihtiyacını karşılamada özbakım yetersizliği tanısına ilişkin karar ağacı	57
Şekil 4.4 Giyinmede özbakım yetersizliğini tanısına ilişkin karar ağacı	58
Şekil 4.5 Konstipasyon tanısına ilişkin karar ağacı.....	59
Şekil 4.6 Beden imajında bozulma tanısına ilişkin karar ağacı.....	60
Şekil 4.7 Sözel iletişimde bozulma tanısına ilişkin karar ağacı.....	61
Şekil 4.8 Stres inkontinansı tanısına ilişkin karar ağacı.....	61
Şekil 4.9 Doku bütünlüğünde bozulma riski tanısına ilişkin karar ağacı.....	62
Şekil 4.10 Düşme riski tanısına ilişkin karar ağacı.....	63

Şekil 4.11 Gastrointestinal mobilitede bozulma riski tanısına ilişkin karar ağacı....	64
Şekil 4.12 Kan şekeri düzeyinde dengesizlik riski tanısına ilişkin karar ağacı.....	65
Şekil 4.13 Kanama riski tanısına ilişkin karar ağacı.....	66
Şekil 4.14 Karaciğer fonksiyonunda bozulma riski tanısına ilişkin karar ağacı.....	67
Şekil 4.15 Kardiyovasküler fonksiyonda bozulma riski tanısına ilişkin karar ağacı.....	68
Şekil 4.16 Aspirasyon riski tanısına ilişkin karar ağacı.....	69

TABLOLAR DİZİNİ

Tablo 4.1.1.1 Banyo yapmada özbakım yetersizliği tanısına ilişkin veriler ve doğruluk oranı tablosu	37
Tablo 4.1.2.1 Beslenmede özbakım yetersizliği tanısına ilişkin veriler ve doğruluk oranı tablosu.....	38
Tablo 4.1.3.1 Tuvalet ihtiyacını karşılamada özbakım yetersizliği tanısına ilişkin veriler ve doğruluk oranı tablosu	39
Tablo 4.1.4.1 Giyinmede özbakım yetersizliği tanısına ilişkin veriler ve doğruluk oranı tablosu.....	40
Tablo 4.1.5.1 Konstipasyon tanısına ilişkin veriler ve doğruluk oranı tablosu.....	41
Tablo 4.1.6.1 Beden imajında bozulma tanısına ilişkin veriler ve doğruluk oranı tablosu.....	42
Tablo 4.1.7.1 Sözel iletişimde bozulma tanısına ilişkin veriler ve doğruluk oranı tablosu.....	43
Tablo 4.1.8.1 Stres inkontinansı tanısına ilişkin veriler ve doğruluk oranı tablosu...	44
Tablo 4.1.9.1 Cerrahi iyileşmede gecikme riski tanısına ilişkin veriler ve doğruluk oranı tablosu.....	45
Tablo 4.1.10.1 Doku bütünlüğünde bozulma riski tanısına ilişkin veriler ve doğruluk oranı tablosu.....	46
Tablo 4.1.11.1 Düşme riski tanısına ilişkin veriler ve doğruluk oranı tablosu	47
Tablo 4.1.12.1 Gastrointestinal mobilitede bozulma riski tanısına ilişkin veriler ve doğruluk oranı tablosu	48
Tablo 4.1.13.1 Kan şekeri düzeyinde dengesizlik riski tanısına ilişkin veriler ve doğruluk oranı tablosu	49
Tablo 4.1.14.1 Kanama riski tanısına ilişkin veriler ve doğruluk oranı tablosu	50
Tablo 4.1.15.1 Karaciğer fonksiyonunda bozulma riski tanısına ilişkin veriler ve doğruluk oranı tablosu	51
Tablo 4.1.16.1 Kardiyovasküler fonksiyonda bozulma riski tanısına ilişkin veriler ve doğruluk oranı tablosu.....	52
Tablo 4.1.17.1 Aspirasyon riski tanısına ilişkin veriler ve doğruluk oranı tablosu	53

SİMGELER VE KISALTMALAR DİZİNİ

ABD	Amerika Birleşik Devletleri
ALT.....	Alanin aminotransferaz
ANA.....	American nurses association
AST.....	Aspartat aminotransferaz
BT.....	Bilgisayarlı tomografi
BUN.....	Blood urea nitrogen
BX.....	Biyopsi
Ca.....	Kalsiyum
CIN.....	Cervikal intraepitelyal neoplazi
Cl.....	Klor
DEHB.....	Dikkat eksikliği hiperaktivite bozukluğu
Dir Bil.....	Direkt bilirubin
DSÖ.....	Dünya sağlık örgütü
ERAS.....	Enhanced recovery after surgery(cerrahi sonrası hızlandırılmış iyileşme)
GGT.....	Gama glutamil transferaz
HGB.....	Hemogloblin
HPV.....	Human papilloma virus
IVF.....	İn vitro fertilizasyon
INR.....	International normalized ratio
İCD.....	International classification of disease (Uluslararası hastalık sınıflandırması kodları)
K.....	Potasyum
Mg.....	Magnezyum
MIT.....	Milli istihbarat teşkilatı
MRG.....	Manyetik rezonans görüntüleme
Na.....	Sodyum
NANDA.....	North american nursing diagnosis association
P.....	Fosfor
PLND.....	Pelvik lenf nodu diseksiyonu
TAH+BSO.....	Total abdominal histerektomi+bilateral salpingooferektomi
Tot Bil.....	Total bilirubin
YSA.....	Yapay sinir ağları
YÜT.....	Yardımcı üreme teknikleri

1. GİRİŞ

Yapay zeka, kompleks tıbbi verileri analiz edebilen bir bilgisayar bilimi dalıdır. Bir veri setindeki anlamlı ilişkiyi kullanma potansiyelleri, birçok klinik senaryoda tanı, tedavi ve sonucu tahmin etmede kullanılabilir (Ramesh vd. 2004). Yapay zekanın genellikle robotların icadıyla başladığı kabul edilir. Resmi olarak yapay zeka 1956 yılında ortaya çıkmıştır (Hamet ve Tremblay 2017). Sanayi alanında yaşanan gelişmeler sağlık açısından birçok etki yaratmıştır. Yapay zeka teknolojilerinin gelişimi Sağlık 4.0 kavramının içerisinde yer almaktadır. Dünya sağlık örgütünün (DSÖ) sağlık vizyonu bağlamında dijital sağlık için küresel strateji raporu yayınlanmıştır. Bu raporun içerisinde dijital sağlık kavramı “sağlığı iyileştirmek ve geliştirmek için dijital teknolojilerin benimsenmesi” olarak belirtilmektedir (WHO. 2019).

Sağlıkta yapay zeka karmaşık verilerin analizi ve veriler için anlamlı sonuçların ortaya çıkması amacıyla çalışılmaktadır. Yapay zeka insan yetilerinden olan öğrenme eylemini taklit edebilmesinden dolayı sağlık alanında birçok yönden çalışılmaktadır (Choi 2020). Bu çalışma alanları hastalık teşhisi, sınıflandırılması, tespit edilmesi, öngörülmesi, tanılanması, risk derecelerinin tayini, izlenmesi prognoz takibi gibi birçok alanı içermektedir. Bunlara ek olarak tıbbi görüntülerin işlenmesinde de çalışmalar yoğunlaşmıştır (Hoşgör ve Güngördü 2022).

Kadın sağlığıyla alakalı birçok çalışma bulunmaktadır. Jinekolojik kanserleri teşhis etmek adına yapılan çalışmalarda doğruluk oranlarının arttığı görülmektedir (Akazawa ve Hashimoto 2020, Takahashi vd. 2021). Ayrıca rahim ağzı kanserine neden olan human papilloma virüs (HPV) virüsünün hangi türünün nüks ve kanserleşme durumlarındaki riskler ortaya çıkarılmıştır (Bagoni vd. 2019). Yapay zeka radyolojik alanında birçok çalışma içermektedir. Kadın kanserlerinin en başında yer alan meme kanseri teşhisi için yapılan çalışmada radyologla kıyaslandığı zaman yapay zekanın eşit

performans gösterdiği sonucuna ulaşılmıştır (Sechopoulos vd. 2020). Kadın sağlığıyla ilişkili diğer çalışma alanları ise osteoporoz, yardımcı üreme teknikleri (YÜT), tekrarlayan gebelik kaybı gibi alanları içermektedir (Ferizi vd. 2019, Goyal vd. 2020 Huang vd. 2021).

Hemşirelik mesleğine yapay zekanın ilk girişi robotlar üzerinde olmuştur. Hastaya pozisyon vermek veya kaldırmak gibi fiziksel eylemleri desteklemek amacıyla iskelet sistemlerinden oluşan robotlar hemşirelikte ilk kullanılanlardır. Daha sonra gelişim göstererek malzemeleri getirebilen veya hasta-uzman arasında iletişim sağlayabilen robotlar geliştirilmiştir. Özellikle pandemi süreci yaşlılarla ilişkili çok farklı boyutları ele almamıza neden olmuştur. Yaşlıların özbakım ihtiyaçlarını desteklemek adına robot yapım çalışmaları bulunmaktadır (Clancy 2020). Hem hastaların sağlığını desteklemek hem de hemşirelerin bakım için ayıracağı süreyi artıracığı bilinmektedir (Ersoy Altınok 2019). Ayrıca hemşire gözleminde yer alan hastanın anlık yaşam fonksiyonlarını değerlendirip acil oluşan durumlarda sinyaller iletebilen yapay zeka uygulamaları bulunmaktadır. Bu yapay zeka uygulamaları hastaların sağ kalım oranlarını yükseltmektedir (Barrett vd. 2019).

Hemşirelik sürecinin en önemli basamaklarından birisi hemşirelik tanıdır. Hemşirelik süreci içerisinde veri toplama, toplanan verilerle doğru hemşirelik tanılarını koyabilme, planlama yapma ve zamanı iyi yönetme gibi tüm basamaklarda teknoloji destek alınması oldukça önemli bir durumdur (Clipper vd. 2018). Hemşirelik tanılarında yapay zeka üzerine az sayıda çalışma bulunmaktadır. Bu açıdan araştırmamızdan elde edilecek sonuçların literatüre önemli bir katkı sağlayacağına inanmaktayız. Bizden sonra yapılacak olan çalışmalar içinde yol gösterici olacağını düşünmekteyiz.

1.1. Amaç

Hemşireler için en önemli yol gösterici olan NANDA hemşirelik tanılarının içerisinde yer alan Jinekonkojik hastalarında konulan hemşirelik tanılarının daha etkin hemşirelik tanılarının elde edilmesi amaçlanmıştır.

2. KURUMSAL BİLGİLER VE LİTERATÜR TARAMASI

2.1.Yapay Zeka

Yapay zeka; insan zekasının yeteneklerinden olan akıl yürütme, anlam çıkarma, genelleme yapma, geçmiş deneyimlerle öğrenebilme gibi yetileri makineye veya bilgisayarlara kazandırabilmektir (Yılmaz 2017). Yapay zekanın temel amacı insan düşünme algoritmasını çözümlene fikrinden oluşmasından dolayı tarihinin Aristoteles'e kadar dayandığı söylenebilir. Tarihi kaynaklarda Aristoteles düşünce algoritması çalışmaları yaptığı fakat başarı elde edemeyip bu konu hakkında zorluklara değinmiştir. İkinci dünya savaşında ilk bilgisayarın icat edilmesi ile birlikte bilgisayar yazılımları başlamıştır ve bu sayede yapay zeka gerçek teknolojik manada ortaya çıkmıştır. Bilgisayarın icadı ile savaşın seyrini değiştiren Alan Turing 1950 yılında Makinalar düşünebilir mi? sorusuyla yapay zeka fikrini ilk ortaya atan kişidir. Turing ilerleyen zamanlarda insanları makinelerden ayırt etmek için Turing testini ortaya çıkartmıştır (Bilge 2007, Turing 1950). Geliştirmiş olduğu bu testte bir insanı, başka bir insanla veya bir bilgisayarla eşleyerek performansını değerlendirmeyi hedeflemiştir. İki arasındaki ayrımı yapmak mümkün olmasa da test başarılı kabul edilmiştir (Kolanska vd 2020). Minsky ve McCarthy tarafından 1956 yılında bir konferansta yapay zeka teriminden ilk defa bahsetmişlerdir.

Yapay zeka üzerinde fikir birliğine dayalı tek bir tanımlama mevcut değildir, çoklu yaklaşımlar şunları içerir:

- Bilgiyi işlemek; insani, sosyal veya mesleki hedeflerimize ulaşmak için bilişsel kapasiteler,
- Bir amaç doğrultusunda hareket etme, mantıklı düşünme ve çevresiyle faydalı bir şekilde ilişki kurma becerisi,

- Yeni durumları tanıma, anlama ve bunlara uyum sağlama ve karşılaşılan güçlüklerle çözüm bulma yetisi,
- Çevreye, herhangi bir soruna ve diğer canlılara uyum sağlama.

Bu çoklu yaklaşım mantıkları ele alındığı zaman aslında evrim esnasında doğadaki canlılarla paralel davranış bilinçlerinin olduğu görülmektedir. Örneğin bitkiler ve ağaç kökleri arasında bir etkileşim bulunmaktadır veya yunusların, şempanzelerin, arıların, kuşların, karıncaların, köpeklerin ve diğer birçok türün bireysel ve toplumsal davranışları mevcuttur (Klonska vd 2020, Schwalbe ve Wahl 2020). Bu mantıkla yapay zeka birçok alanda hesaplama gücü ve anlık hesaplamalar kullanılarak, daha önceden işlenen verilere göre elde edilen yeni verilerde gerçek zamanlı olarak değerlendirme yetisiyle insan hayatını kolaylaştırmaktadır (Mintz ve Brodie 2019).

Günümüzde yapay zeka, toplumun her kesiminden insanların hayatına kişisel asistanlar, otomatik toplu taşıma, havacılık, bilgisayar oyunları gibi bir çok alanda entegre olmuştur (Çoşkun ve Gülleroğlu 2021). Son zamanlarda yapay zekadaki yeni gelişmeler doğrultusunda hasta teşhisinde daha fazla doğruluk elde etmek ve hasta bakımını iyileştirmeye adapte olunmuştur. Radyolojik görüntüler, patoloji gibi birçok alan makine öğrenimi ile değerlendirilip hastaların teşhis ve tedavi sürecine yardımcı olarak sağlık personelinin yeteneklerini artırmaktadırlar (Mintz ve Brodie 2019).

2.1.1. Sağlıkta yapay zeka

Sağlık hizmetleri her kişi için temel bir gereksinimdir. Fiziksel varlığın gerçekleştirilmesi için sağlık, Maslow'un ihtiyaç piramidinin temel basamağında yer almaktadır. Sağlık hizmetleri hem sosya-kültürel hem de ekonomik bağlamda çeşitlendirilebilir entegre bir hizmet dalıdır. Bu hizmet dalı tanı, tedavi, sağlığın iyileştirilmesi ve rehabilitasyon aşamalarını içermektedir ayrıca süreçler birbiriyle bütünlük oluşturmaktadırlar. İyi bir sağlık sistemi, hastalık oluşmadan önlemek, var olan hastalığın ilerlemeden tanısını koymak, gerekli tedaviyi uygulamak, tedavi sonrası rehabilitasyonu oluşturmak ve toplumu bilinçlendirerek sağlık okur yazarlığının artmasını sağlamaktadır. Sağlık hizmetlerinin kalitesi, erişilebilir olması ve maliyeti günümüzde gelişme gösteren dallar arasında yer almaktadır (Akalin ve Veranyurt 2021, Altundaş 2019).

Teknolojide yaşanan gelişmeler yaşam kalitesini her zaman pozitif yönde etkilemektedir. Endüstride yaşanan gelişmeler sağlık alanına uyarlandığı zaman Sağlık

1.0, Sağlık 2.0, Sağlık 3.0 ve Sağlık 4.0 kavramları ortaya çıkmıştır (Chen vd 2020). Sağlık 1.0'de aşı gelişmelerinin, 2.0'de seri üretim ile birlikte ilaç üretiminin gelişip yeni antibiyotiklerin ortaya çıkmasını, 3.0 bilgisayar ve bilgi teknolojileri sonucunda radyolojik alanında gelişmeleri, 4.0'da ise yapay zeka tabanlı gelişmeleri içermektedir (Klonska vd 2020). Yapay zekanın karmaşık biyomedikal sorunları özel olarak çözmek veya açıklığa kavuşturmak için kullanılabileceğinin ortaya çıkmasıyla birlikte, potansiyelindeki ilgi katlanarak artmıştır ve bunun sonucunda da sağlık alanına girmeye başlamıştır. Warner ve ark. tarafından 1961 yılında konjenital kalp hastalığı sonucunda kardiyak kateterizasyon nedeni ile sevk edilen ve analiz edilen 1035 hastadan veriler alınıp otomatik bir teşhis sistemi kurulması üzerine bir çalışma yapılmıştır (Warner vd.1961). Teşhis ile ilgili yapılan bu ilk araştırmanın ardından 1970 yılında Stanford üniversitesinde geliştirilen bir bilgisayar programı ile hastalığın teşhisine ek olarak, antibiyotik önerme ve neden olan bakteriyi belirleyip vücut ağırlığına göre doz ayarının belirlenmesi için bir diğer çalışma yapılmıştır. Yapay zekanın akıllı bilgisayar destekli eğitimi ile türetilen GUIDON isimli program tıp öğrencilerine bulaşıcı hastalıkların teşhisini öğretmek için 1970 yılının sonlarında geliştirip kullanılmıştır (Clancey ve Buchanan 1979). Daha başka yapay zeka sistemleri de geliştirilerek teşhis bazında ilerlemeler ele alınmış ve farklı sistemlerin karşılaştırmaları yapılmıştır (Kulikowski ve Weiss 1982). İlerleyen dönemlerde yapılan çalışmalarda hekimlerin teşhis koyma yetenekleri ile yapay zekanın yeteneklerini karşılaştıran çalışmalar yapılmıştır. Yapay zeka sistemlerinin değerlendirildiği bu çalışmaların sonuçlarına göre sistemlerin objektif bir yaklaşımla hekimlerin teşhisine yardımcı olduğu ve teşhisi kuvvetlendirdiği bildirilmiştir (Adams vd.1986, Dombal vd. 1972). Yapay zeka tarihinin ilk dönemlerinde yapılan bu çalışmalar şimdi uygulanan birçok çalışmaya ışık tutmuştur.

Yapay zeka gelişim süreçlerinde ilk adım sınırsız miktarda organize verinin toplanması, ikinci olarak anlık iletişim ağını oluşturan internetin ortaya çıkması ve üçüncü olarak verilerin anında otomatik olarak işlenmesini içermektedir. Yapay zeka dönüşümünü sağladığı tıbbi uygulamalarda dahil olmak üzere üstel bir gelişim geçirmektedir (Klonska vd 2020). Bu gelişimlere paralel robotlar, kuantum bilgisayarlar, sanal gerçeklik gibi birçok yeni teknoloji dalı mevcuttur (Akalın ve Veranyurt 2022).

Küresel sağlık araştırmaları referans alınarak yapay zeka güdümlü sağlık çalışmaları dört kategoriden oluşmaktadır. Bunlar teşhis, hastanın morbidite veya mortalite riskinin analizi, salgın hastalık tahmin edilmesi ve gözlemi, sağlık politikaları ve planlamalarıdır. Yapay zeka güdümlü sağlık müdahaleleri, düşük ve orta gelirli ülkelerde daha iyi sağlık sonuçlarına yol açacağı düşünülmektedir (Schwalbe ve Wahl 2020).

Yapay zeka, büyük verilerin gücünü açığa çıkarma ve kanıta dayalı klinik karar vermeyi desteklemek ve değere dayalı bakım elde etmek için içgörü kazanma potansiyeli nedeniyle sağlık hizmetlerinde hızla gelişmektedir (Chen ve Decary 2020). Sağlıkta yapay zeka araştırma alanları içerisinde hastalık teşhisi, sınıflandırılması, tespit edilmesi, öngörülmesi, tanılanması, risk derecelerinin tayini, izlenmesi prognoz takibi gibi araştırma dalları bulunmaktadır. Aynı zamanda tıbbi görüntülerin işlenmesi, sağlık hizmetleri yönetimi, hekim görüşlerinin saptanması gibi çeşitli alanları içermektedir (Hoşgör H, Güngördü 2022). Sağlık liderlerinin yapay zeka teknolojilerinin durumunu ve bu teknolojilerin sağlık hizmetlerinin dijital dönüşümünü destekleyerek sağlık hizmetlerinin verimliliğini, güvenliğini ve erişimini iyileştirmek için nasıl kullanılabileceğini anlamaları çok önemlidir (Chen ve Decary 2020).

2.1.2. Kadın sağlığında yapay zeka

Yapay zeka kadın sağlığıyla ilgili birçok çalışma kullanılmıştır. Jinekolojik kanser teşhisi için yapılan birçok çalışmada olumlu sonuçlara ulaşılmıştır. Endometriyal kanser zaman içerisinde artış gösteren ve dünyanın birçok yerinde yaygın olarak görülen jinekolojik kanser türlerinden birisidir. Yaygın kullanılan bir tarama tetkiki olmamasına rağmen erken teşhis oldukça önemlidir. Yapılan bir araştırmaya göre; histeroskopi görüntülerden elde edilen bilgiler ışığında, yapay zeka tabanlı bir sistem kurulmuştur. Bu çalışmaya 177 hasta dahil edilmiştir, 60 normal endometrium görüntüsü, uterin miyomu, polip, atipik endometriyal hiperplazi ve endometriyal kanser görüntüleri de bulunmaktadır. Çalışmanın sonucunda tanı doğruluğunun %80'lerden %90 ve üzerine çıktığı görülmektedir. Yapılan çalışma endometriyal kanserin teşhisini kolaylaştırmak için bir araç olduğu görülmektedir (Takahashi vd 2021). Histeroskopik görüntüler ile endometriyal lezyonları ve endometriyal lezyon tipini doğru bir şekilde tespit etmek amaçları ile de farklı bir çalışma yapılmıştır. Bu çalışmada kanser öncesi dönemde jinekologlara oranla daha yüksek duyarlılıkla başarılı olması sebebi ile kişisel teşhiste yapay zekanın önemi vurgulanmaktadır (Zhang vd. 2021).

Endometrium kanserinde olduğu gibi over kanserinin de tarama testi yoktur ve geç dönemlerde tanı konulduğu için nüks oluşturma oranı yüksektir. Erken teşhis, tedavi sürecinden cerrahi sürece kadar birçok alanda olumlu değişikliklerin olmasını yol açmaktadır (Stewart vd 2019). Over kanseri teşhisi için yapılan bir yapay zeka çalışmasında, 202 hastadan kan testi sonuçları, hastanın öyküsü, görüntüleme testleri ve ameliyat öncesi muayeneden elde edilen bilgiler ile birlikte beş farklı derin öğrenme

yöntemi kullanılarak oluşturulmuştur. Çalışmanın sonucunda over kanserinin patolojik tanısının preoperatif muayenelerden tahmin edilmesinde rol oynayabileceği sonucuna varılmıştır (Akazawa ve Hashimoto 2020).

Rahim ağız kanseri jinekolojik kanserler mortalitesi açısından ikinci sırada yer almaktadır. HPV ile enfekte olmuş ve kalıcı enfeksiyonu olan hastalarda servikal intraepitelyal neoplazi (CIN) yakından ilişkilidir. Gelişmiş olan ülkelerde HPV tarama periyotları artırılmıştır. Tarama programlarının artırılması birlikte pozitif olan kadınlar için periyodik gözlem dışında bir yöntem bulunmamaktadır (Fan vd. 2018). Yapay zeka teknolojisi kullanılarak, tedavi öncesinde HPV genotipinin servikal displazi kalıcılığı ve nüksü riskini öngörüp öngörmeyeceğini belirlemek amacıyla bir çalışma yapılmıştır. Çalışmanın sonucunda HPV'nin bazı türlerinin nüks ve kanserleşme durumlarında risk oluşturabileceği ortaya konmuştur. Bu nedenle yapay zeka teknolojilerinin kişiye özel tedavi ve ek aşılama programları için avantaj sağlayacak bir teknoloji olduğu sonucuna varılmıştır (Bogani vd. 2018).

Preasetik asit testi ve postasetik asit testinin kolposkopi görüntüleri ile CIN teşhisi için kullanılan bir yöntem olduğu bilinmektedir. Yapılan bir çalışmaya göre elde edilen bu görüntülerle birlikte yapay zeka teknolojisi birleştirilerek CIN teşhisi için özgünlük, doğruluk ve duyarlılık açısından oldukça yüksek tahminlerin ortaya çıktığı bildirilmiştir (Peng vd. 2021). Uterin adenosarkom hastası olan 797 kişinin hayatta kalma tahmini için geliştirilen derin öğrenme yöntemleri ile yapılan bir çalışmada kişiselleştirilmiş prognozlarda yüksek oranda doğru tahminlerin yapıldığı bildirilmiştir (Qu vd. 2021). Jinekolojik kanserlerde yapay zekanın gelişimini ele alan bir derlemede, teşhis koyma doğruluğu ve erken teşhis tahmini ele alınmaktadır. Ancak, yapay zeka daha tam olarak insanlaştırılmadığı için ilerleyen dönemlerde etik, sağlık sigortası gibi bir çok ahlaki açıdan sorunların olacağı da vurgulanmaktadır (Zhou vd. 2021).

Meme kanseri taramasının kadınlarda ölüm oranını önemli ölçüde azalttığı gösterilmiştir. Tarama muayenelerinin artan kullanımı, hızlı ve doğru teşhis raporlaması için artan taleplere yol açmıştır. Gelişen tarama testleri ile meme kanseri teşhisinde yapay zeka teknolojisi oldukça önemli bir yol almıştır (Tran vd. 2021). Son beş yıldır yapay zeka teknolojisi derin öğrenme ve sinir ağları tarafından geliştirilen sistemler ile özellikle kadın hastalıkları alanında en çok çalışılan konu olan meme kanseri teşhisi için dijital mamografi görüntüleri kullanılmıştır. Meme kanseri teşhisi için geliştirilen yapay zeka teknolojisinde ticari ürünler ortaya çıkmıştır. Gelişen bu teknolojilerden elde edilen çalışmalara göre deneyimli radyologlarla kıyaslandığı zaman yapay zeka teknoloji performansının eşit olduğu sonucuna varılmıştır. Olumlu sonuçlar elde edilen birçok

çalışmanın ışığında gelecekte meme kanseri teşhisi için yapay zeka teknolojisi önemli bir role sahip olacağı netlik kazanmış durumdadır (Sechopoulos vd. 2020).

Menopoz döneminin başlaması ile kadın sağlığını derinden etkileyen osteoporoz için de yapay zeka teknolojileri geliştirilmiştir. Bu teknoloji osteoporoz riskini hesaplayıp değerlendire bilmektedir. Kemik kırığı riski taşıyan hastaların daha önceden belirlenmesi için çalışılan yapay zeka teknolojisi çalışmasında farklı derin öğrenme metotları kullanılarak osteoporoz kırıklarının önceden belirlendiği görülmüştür (Ferizi vd. 2019).

İnfertilite tedavisinde YÜT vazgeçilmez bir konu olmuştur. YÜT uygulamalarında karar verme aşaması klinisyen merkezli çalışılmaktadır, karar verme süreci hekimin tecrübesine ve kanıta dayalı uygulamalara dayanmaktadır. YÜT uygulanmasının nedeni birçok faktöre dayanmaktadır. İn vitro fertilizasyon (IVF) uygulaması, endometriozis, kötü yumurta kalitesi, anne veya babanın genetik bir hastalığı, yumurtlama sorunları, sperm veya yumurtalara zarar veren antikor problemleri, spermin nüfuz edememesi veya hayatta kalamaması gibi komplikasyonları gidermenin popüler bir yöntemidir. IVF uygulaması hem yüksek maliyetli hem de sonucu belirsiz olduğu için oldukça zahmetli bir süreçtir (Goyal vd. 2020). Tekrarlayan gebelik kaybı ve tekrarlayan implantasyon başarısızlığı gibi tekrarlayan üreme yetmezliği, karmaşık etiyolojilerle karakterizedir ve özellikle çeşitli maternal faktörlerle ilişkilidir. Halen, tekrarlayan üreme yetmezliğinin maternal ortam ile yakından ilişkili olduğuna ve bunun da karmaşık bağışıklık faktörlerinden etkilendiğine inanılmaktadır. Otomatik araçlar kullanılmadan, çeşitli bağışıklık faktörlerinin gebelik sonucu üzerindeki etkileşimini ve sinerjik etkilerini değerlendirmek genellikle zordur. Bu gibi nedenlerden dolayı yapay zeka teknolojisi yardımcı üreme teknikleri alanında araştırılmaya başlanmıştır. Yapılan bir çalışmaya göre; biyokimyasal gebelik, klinik gebelik, devam eden gebelik ve canlı doğum da dahil olmakla birlikte dört farklı gebelik düğümündeki gebelik sonuçlarını tahmin etmek için farklı veri panelleri oluşturulmuştur. Teşhis için kullanılan parametreler; hormon seviyeleri, otoantikörler, periferik immünoloji, endometrial immünoloji ve embriyo parametreleridir ve bu veriler 64 değişkeni içermektedir. Çalışmanın sonucuna göre; tekrarlayan gebelik kaybı olan hastalar için daha kesin ve kişiselleştirilmiş tanı ve tedavi planlamasına yardımcı olmak için temel oluşturabileceği bu sayede klinisyenlerin daha doğru tedavi etmesinde bir ışık olacağı sonucuna varılmıştır (Huang vd. 2021). Yapılan başka bir çalışmaya göre yine paralel sonuçlar elde edilip IVF tedavisinde yapay zeka teknolojisinin tanı tedavi ve canlı doğum tahmini yönünden olumlu sonuçlar elde edilmiştir (Goyal vd. 2020). Kadın hastalıkları ve doğurganlıkla ilişkili yapılmış olan bu olumlu sonuçlar doğrultusunda yapay zeka teknolojisi yardımcı üreme tekniklerinde de kullanılmıştır (Letterie 2021).

Ayrıca kısa servikal uzunluğa sahip asemptomatik gebe kadınlardan alınan amniyotik sıvı ile birlikte yapay zeka teknolojileri kullanılarak perinatal sonuç tahminleri değerlendirilen bir çalışmada; altı farklı derin öğrenme makine tekniği kıyaslanarak değerlendirilmiştir. Hasta popülasyonu sınırlı olan bu çalışmada bazı derin öğrenme yöntemlerinin diğerlerine göre daha iyi olduğu sonucuna varılmış ve genel olarak yapay zeka teknolojisi perinatal sonuçları doğru olarak tahmin etmiştir (Bahado-Singh vd. 2019). Fetal kalp hızı taramaları için geliştirilen yapay zeka teknolojisi ile fetal asfiksiyi doğru tahmin edebildiği sonucuna da varılmıştır (Zhao vd. 2019).

2.1.3. Hemşirelikte yapay zeka

Hemşirelik mesleği insan sağlığı ve refahının bir bütünü olarak ideal değerlerden oluşan bilgi disiplinine dayanan uygulama mesleğidir. Bilgisayarın icadından sonra teknoloji çağının başlaması ile robot teknolojisi ve yapay zeka sistemleri hayatımıza girmiştir (Locsin ve Ito 2018). Yapay zeka teknolojisi tüm meslek gruplarında olduğu gibi hemşirelik alanında da kullanılmaya başlanmıştır. Bu sayede hemşirelik bakımı için hasta daha yakından tanınmakta ve hasta güvenliği artmaktadır. Bu durumun tersine Watson ve arkadaşları, çeşitli teknolojik ağı veya aygıt kullanımının hemşireleri hasta başından uzaklaştıracağını düşünmektedirler (Carroll 2018). Başka bir görüşte ise hemşirelik bakımına katkı sağlaması için bakıma ortak edilerek kullanımının doğru olacağı savunulmaktadır. Bu fikirde hemşirelik mesleği görevlerinin yapay zeka ile birlikte görev paylaşımının görece yeterliliğe uygun bir yöntemle bölünebileceği belirtilmiştir (Clancy 2020).

Hemşirelik mesleğine yapay zekanın ilk girişi geliştirilen robotlarla olmuştur. Hastaya hemşirelik bakımı için yatak içinde pozisyon verilirken ciddi kas gücüne ihtiyaç duyulmaktadır. İlaç vakitlerini hatırlatması, kas gücüne yardım etmesi, çeşitli evrak işleri ile ilgilenmesi aslında hemşirenin bakım için ayıracağı süreyi artırmaktadır (Ersoy Altınok 2019). Ayrıca geliştirilen robotlar sayesinde hemşirelerde sakatlık ve hastalıkların oluşma riski en aza ineceği düşünülmektedir (Bacaksız vd. 2020). Ameliyat esnasında ellerin anatomik sınırlılıklarını ortadan kaldıran Da Vinci cerrah kontrollü robotlar ameliyat hemşiresinin sorumluluğunu indirgemekte aynı zamanda cerrahın ameliyat verimliliğini artırmaktadır (Locsin ve Ito 2018). Yapay zeka tabanlı ameliyat sistemi ile intertrokanterik femur kırığı ameliyatlarında X-ışını değerlendirme görüntüleriyle gama çivi ameliyatına rehberlik etmek için kullanılmıştır. Yapay zeka tabanlı ameliyat sisteminin kullanılması kontrol grubuna kıyasla hemşirelik bakımından elde edilen verimin daha iyi olmasına

ayrıca hastanın iyileşme süresini kısalttığı sonucuna varılmıştır (Wang vd. 2021). Yapılan başka bir benzer çalışmada yapay zeka robot yardımcı göğüs cerrahisinin postoperatif hemşirelik etkisini değerlendirilmiştir. Yapay zeka robotu yardımı ile yapılan ameliyatlarda daha az travma, daha az ağrı, daha hızlı iyileşme, daha güvenli ve daha kapsamlı lenf nodu diseksiyonu avantajlarına sahip olduğu görülmüştür. Bu sonuçlardan doğrultusunda da yapay zeka tabanlı yapılan ameliyatlarda hemşirelik bakım süreçleri daha verimli geçmektedir (Hu ve He 2021).

Hemşirenin zaman kazanımı için geliştirilmiş TUG isimli robotları ise laboratuvar numune, hasta yiyeceği, örtüsü gibi malzemeleri belirlenen varış yerlerine ulaştırmaktadır (Mccarthy 2004). Ayrıca hemşirenin fiziksel yetersizliğini sağlayabilecek hastayı sandalyeye koyma, kaldırma veya tekerlekli sandalyeye koyma gibi komutları yerine getirebilen 'Ro-bear' isimli robot aynı zamanda mobilizasyona da yardımcı olmaktadır (MacFie ve McNaught 2015). Ayrıca robot teknolojisine yapay zekanın entegre edilmesi ile insan gibi düşünüp hareket edebilen robotlar geliştirilmektedir. Örneğin demans hastalarında ruh halini pozitif yönde etkilemek için ve ağrı düzeyini değiştirebilen PARO isimli robotlar geliştirilmiştir (Mcgrow 2019). Küresel yaşlanma giderek daha ciddi hale gelmektedir ve gelecekte yaşlıların hemşirelik bakımdan doğan sorunları daha da artacaktır. Bu soruna paralel olarak geliştirilen robotlarda üç boyutlu insan eklemlerinin tahmini için evrişimli sinir ağı yapısı kullanılarak daha işlevsel robotlar geliştirmek için çalışmalar yapılmaktadır (Cai vd. 2021). Yapay zeka ve robotlara ilişkin hemşirenin görüşlerini inceleyen bir çalışmada, %86'sı ilerde robotların hemşirelerin yerini alacağına inandığını belirtmiştir. Fakat birçok hemşire aynı zamanda iş yüklerinin de azalacağını belirtmiştir (Ergin vd. 2022).

İş yükünün çok yoğun olduğu hemşirelik dallarından birisi acil hemşireliğidir. Acil servislere başvuran hasta sayısının çok fazla olması ve aynı anda kritik müdahalelerin yapılmasından dolayı sağlık personelinin iş verimliliğinin artırılması için yeni çalışmalara ihtiyaç duyulmaktadır. Yapılan bir çalışmada acil servise sıklıkla başvuran hasta grupları olan ani kalp hastalığı, felç, şok gibi 10 acil hasta grubunun son üç yıllık hastalık verilerini kullanılmıştır. İlk yardım hemşireliği yönetim sistemini incelemek için acil geliştirilen yapay zeka algoritmasında, triyaj süresi ve triyaj doğruluğunun 3 yıl içerisinde anlamlı bir şekilde arttığı görülmüştür (Liu vd. 2022). Yapılan başka bir çalışmada hastane acil bakım yönetimi için tıbbi bilgi madenciliğine dayalı bir görsel yapay zeka sistemi seti tasarlanmıştır. Görsel olarak geliştirilen bu yapay zeka sisteminde, acil ilk yardım hemşirelik yönetim sisteminin ihtiyaçları analiz edilerek klinik çalışmalarda büyük ölçüde kolaylık sağlayacağını öngörmektedir (Dong vd. 2021).

Akut ruh hastalıkları biriminde yatan hastalarda nefes alış kontrollerini yapabilmek için geceleri 15dk da bir veya saat başı hemşirelik gözlemleri yapılmaktadır. Hemşirelik gözlemi hasta güvenliğini sağlamak içindir ancak hastanın uykusu bölünmekte ve bunun sonucunda iyileşme süreleri uzamaktadır. Bu durumu önlemek için vücuttaki mikro hareketleri ve renk değişikliklerini gözleyen ayrıca sinyal iletimi sağlayan yapay zeka yazılımlı bir sensör hasta odalarına yerleştirilmiştir. Çalışmanın sonucunda deney grubunda olan kişilerin hastanede kalış sürelerinin daha kısa olduğu ve gece uyanmalarının deney grubuna göre daha az olduğu sonucuna varılmıştır (Barrera vd. 2020).

Yapay zekanın bir diğer kullanım alanı hemşirelik mesleği eğitimidir. Hemşireler, kapsamlı iletişim ve klinik beceriler gerektiren birçok bakım ortamında ağrının değerlendirilmesi ve yönetiminin ayrılmaz bir parçasıdır. Brezilya'da hemşirelik lisans öğrencileri üzerinde akut ağrının stimüle edilmiş sanal öğrenme uygulamasını değerlendirmek için yapılan bir çalışma 14 lisans öğrencisi üzerinde uygulanmıştır. Ağrı değerlendirilmesinin öğreniminde olumlu sonuçlar ortaya koyup tematik boşlukları doldurduğu görülmüştür (Alvarez ve Sasso 2011). Benzer başka bir çalışmada lisans hemşirelik öğrencilerine ağrı eğitimi için bilgisayar simülasyonunu kullanılmıştır ve eğitime katılım, değerlendirme konusunda pozitif sonuçlar elde edilmiştir (Allred ve Gerardi 2017). Üç boyutlu simülasyon kullanılan başka bir çalışmada da eğitime olumlu katkıları olduğu sonucuna varılmıştır (Enilda 2014). Hemşirelik öğrencilerin iletişim becerilerini geliştirmek için yapılan başka bir çalışmada da dört farklı vaka senaryosundan oluşan sistem üç boyutlu avatar formunda geliştirilmiştir. Çalışmanın çıktılarında hemşirelik öğrencilerinin öz yeterlilik ve etkili iletişim becerilerini geliştirmeye yardımcı olacağı sonucuna varılmıştır (Shorey vd. 2019).

Radyolojik görüntülerin gelişmesi ile konulan doğru teşhis hemşirelik bakım kalitesi artırmaktadır. Örneğin over endometriozisi olan hastaların manyetik rezonans görüntüleme (MRG) özellikleri için klinik olarak over endometriozisi MRG tanısında yapay zeka FCM algoritması uygulanmıştır. Yapay zeka FCM algoritması tanının doğrulanmasında önemli rol oynamaktadır. Klinik tanının doğru olması hemşirelik müdahalesinin de kapsamlı olmasını sağlamıştır ve kontrol grubuna göre hastaların hemşirelik memnuniyetleri daha yüksek olduğu sonucuna varılmıştır (Jiang vd. 2022). Yapılan benzer bir çalışmada hemşirelik bakım kalitesinin artırılması için çocukluk çağı astım hastaların da yapay zeka tabanlı sistem geliştirilmiştir (Li vd. 2022). FCM algoritması kullanılan başka bir çalışmanın çalışma grubu ise diyabetik nefropatili hastalar olmuştur. MRG görüntüleri baz alınarak geliştirilen yapay zeka teknolojisi ile konulan tanılar erken zamanda teşhis edilmesi ile hastalarda iyileşme sürecini

kısaltmakta ve hemşirelik hizmet memnuniyetlerini de artırmaktadır (Du vd. 2022). Benzer başka çalışmada da mikoplazma pnömonisi olan çocuklarda Deming'in döngüsü teoremi baz alınarak; planlama, uygulama, inceleme ve işleme basamaklarıyla yapay zeka teknolojisi kullanılarak hemşireler bakım için eğitim almışlardır. Çalışmanın deney grubunda diğer çalışmalarda olduğu gibi hasta memnuniyeti daha fazla, iyileşme süreci ve hastanede kalış süreci daha kısadır (Zhao 2022). Aynı durum ultrason görüntüsü çalışmaları da geçerlidir. İyi huylu rahim hastalıkları nedeniyle laparoskopik total histerektomi yapılan 120 hastada pelvik taban disfonksiyonunun daha iyi teşhis edilmesi için ultrason görüntülerinde çeşitli yapay zeka algoritmalarının kıyaslandığı bir çalışmada ISCB algoritmasının SCB, SER ve RLS algoritmalarına göre daha iyi olduğu sonucuna varılmıştır. Hem deney hem de kontrol grubu üzerinde uygulanan yapay zeka teknolojisine ek olarak deney grubuna cerrahi sonrası hızlandırılmış iyileşme (ERAS) protokolü kapsamında hemşirelik bakımı verilmiştir. ERAS protokolünün klasik hemşirelik bakımına göre iyileşme sürecinde daha iyi olduğu ayrıca hasta memnuniyetinin daha fazla olduğu sonucuna varılmıştır (Yu vd. 2022).

Hemşirelik mesleğinin bir diğer önemli parçası da hasta eğitimidir. Kronik obstrüktif akciğer hastalığı olan 447 hasta üzerinde yapılan randomize bir çalışmada 4 ve 12 ay sonra yaşam kalitesini değerlendirme için yapay zeka uygulaması kullanılmıştır. Çalışmada 9 aylık web tabanlı bilgi egzersizi uygulanmıştır. Deney grubunda olanların 12 ay sonra yaşam kalitesi, duygusal ve psikolojik koşullarının kontrol grubuna göre daha iyi olduğu sonucuna varılmıştır (Hong vd. 2021). Çocuklarda dikkat eksikliği hiperaktivite bozukluğu (DEHB) en sık görülen nörogelişimsel bozukluklardan biridir. Dikkatsizlik, hiperaktivite, dürtüsellik ve gelişim düzeyine uygun olmayan diğer belirtilerle farklı durumlarda sosyal, akademik ve mesleki açıdan işlevsellikte bozulma ile kendini gösterir. DEHB'li çocukların tedavisi temel olarak ilaç tedavisi ile psikolojik hemşirelik müdahalesine dayanmaktadır. Bu nedenle, bu tedavi rejiminin gerçek etkinlik değerlendirmesi çok önemlidir. Sinir ağları yapay zeka açısından yaygın olarak kullanılmaktadır. Bu çalışma, DEHB'li çocukların klinik tedavi etkilerinin değerlendirilmesi ile yapay zekayı birleştirir ve DEHB'li çocukların ilaç tedavisi ile psikolojik hemşirelik müdahalesinin klinik etkinliğini değerlendirmek için sinir ağlarına dayalı akıllı bir model tasarlanmıştır. Bu sayede hemşirelik bakımının daha verimli olacağına inanılmaktadır (Guo vd. 2022).

2.2. NANDA Hemşirelik Tanıları

2.2.1. NANDA tarihçesi

Amerikan Hemşireler Birliği, beş aşamalı hemşirelik süreçlerinden birisi olan hemşirelik tanıları; tedavi gerektiren belirli hasta sorunlarının tanımı olarak açıklamaktadır (Bakken Henry ve Mead 1997). Hemşirelik sürecindeki klinik karar verme ve bireyselleştirilmiş bakım planının etkin şekilde gerçekleştirilebilmesi için hemşirelik tanılarının doğru analiz edilmesi gerekmektedir (Bakken Henry ve Mead 1997, Kocaçal 2021). Hemşirelik tanısı kavramı 1953'te Virgini Fry tarafından ortaya çıkmıştır (Kocaçal 2021). North American Nursing Diagnosis Association (NANDA) eski adı ile Kuzey Amerika Hemşirelik Tanıları Derneği 1973 yılında St. Louis Üniversite'sinde yapılan ilk toplantısında hemşirelik tanısı terimini hemşirelik sürecine eklenmesi tartışılmıştır. Tanı ifadelerinin düzenlenmesi ve sınıflandırılması 1980'li yıllarda olmuştur. NANDA 1982 yılında bir hemşirelik teorisyeni olan Dr. Marjory Gordon başkanlığında birlik haline dönüşmüş ve bu süreçte hemşire kuramcılar ve üyelerin katılımı ile kongreler düzenlemiştir. Yine aynı yıllarda NANDA'nın hemşirelik dili ve sınıflandırma sistemi American Nurses Association (ANA) tarafından DSÖ'ne iletilmiştir. İş birliği ile geliştirilen model 1987 yılında DSÖ tarafından onaylanmıştır. Uluslararası katılımı hem desteklemek hem de temsil etmek amacı ile 1992 yılında dernek NANDA International adını alarak faaliyetlerini sürdürmeye başlamıştır. NANDA-1, 2000 yılına kadar 9'lu taksonomi sistemini kullanırken, 2000'den sonra toplam 290 hemşirelik tanısı ile NANDA-II kullanılmaktadır (Bakken Henry ve Mead 1997, Kocaçal 2021, McCokmick 1994, NANDA 2023, NANDA THD).

2.2.2. NANDA kullanımı

Hemşirelik, çalışma alanı insan olan bakımı temel alan bir meslek grubudur. Bakım mesleğe atfedilmiş özgünlüktedir. Bütüncül ve sistemli olarak ele alınan hemşirelik bakımı profesyonel bilgi ve deneyim ile yoğurulup, hemşire-hasta ilişkisine yansıtılarak hemşirelik sürecinin güncelliğini ve dinamikliğini korumaktadır (Erer vd. 2017, Dinç 2010). Hemşirelik süreci; kişinin sağlık problemlerini belli bir sistematik süzgeçten geçirerek birbirini peşi sıra takip eden bakım aşamalardan oluşan hemşirelik aktivitelerine denir (Biol 2010). Aynı zamanda hemşirelik süreci içinde bulunduğu evreni tanımlayarak, kişi sağlıklı veya hasta olsun bireysel ve bütüncül bir yaklaşım ile ele alarak bireyin sağlık düzeyini korumak, yükseltmek ve iyileştirmeyi hedeflemektedir. Bu

bütüncül yaklaşım hemşirenin karar verme yeteneğini geliştirmeyi sağlamaktadır (Asmirajanti vd. 2019, Birol 2010). Craven ve Hirnle (2013) tarafından hemşirelik süreci kavramı, kişinin sağlık ve hemşirelik bakımıyla ilgili gereksinimlerini tespit etmek için problemleri çözümlene bakış açısı olarak tanımlanmaktadır.

Birol'a (2010) göre ise sorunları halletmek, bilimsel metotlarla hemşirelik süreci birbirine benzetilmektedir. Hemşirelik süreci beş basamaktan oluşmaktadır bunlar; tanılama, hemşirelik tanısı, planlama yapma, uygulama ve değerlendirme olarak birbirini takip eden aşamalardan oluşmaktadır (Asmirajanti vd, 2019 Özkan ve Bilgin 2016). Beş aşamalı hemşirelik tanıların sınıflandırılması ile ilgili 1973 senesinde Kristine Gebbie ve Mary Ann Lavin ulusal konferanslar düzenlemişlerdir. Bu konferansların sonucun hemşire eğitimcileri ve sahada çalışan hemşireler beş aşamalı hemşirelik sürecini pratikte uygulamaya başlamışlardır. Beş basamağa son yıllarda yapılan çalışmalar neticesinde sürecin üçüncü aşaması olarak kabul edilen "beklenen sonucu tanımlama" da eklenerek aşamalar altıya yükselmiştir. Hemşirelik sürecinde beklenen sonuç aşaması gerçekçi hasta merkezli amaçların formüle edilip, kayıt altına alınması anlamında kullanılmaktadır (Craven vd. 2013). Ülkemizde ise 2010 yılında hemşirenin yetki ve sorumluluklarını belirten 6. Maddede, "Hemşireler; her ortamda bireyin, ailenin ve toplumun hemşirelik girişimleri ile karşılanabilecek sağlıkla ilgili ihtiyaçlarını belirler ve hemşirelik tanılama süreci kapsamında belirlenen ihtiyaçlar çerçevesinde hemşirelik bakımını kanıta dayalı olarak planlar, uygular, değerlendirir ve denetler" hemşirelik sürecine son eklenen aşama benimsenerek yasalaşmıştır. Ayrıca hemşirelik eğitimi içerisinde hemşirelik süreci kullanımın öğretilmesi zorunlu duruma getirilmiştir (Carpenito ve Erdemir 2012). Kayıt altına alınmasının önemini bildiren bir çalışmada, hemşirelerin daha etkili ve uygun şekilde çalışacaklarını belirtmektedir (Paans vd. 2010).

3. GEREÇ VE YÖNTEMLER

3.1 Araştırmanın Tipi

Araştırma Jinekonkolojik hastaların verileri kullanılarak makine öğrenmesi ve veri madenciliği yöntemiyle NANDA hemşirelik tanıların konulmasıdır.

3.2. Araştırmanın Yeri ve Zamanı

Araştırmanın verileri, 2015-2021 tarihleri arasında Jinekonkoloji tanısı almış (Over kanseri, Serviks Kanseri, Vulva kanseri, Tuba Uterina Kanseri, Uterus Kanseri) hastaların bilgileri Pamukkale Üniversitesi Sağlık Araştırma ve Uygulama merkezinden 02.07.2021 tarihinde elden alınmıştır (Protokol No: E-65124556-600-81282).

3.3. Araştırmanın Değişkenleri

Bağımsız değişkenler: Katılımcının cinsiyeti, yaşı, hastaneye yatış yılı, kan tahlilleri (Hemogloblin (HGB), International Normalized Ratio (INR), Glukoz, Blood Urea Nitrogen (Bun), Üre, Kreatinin, Sodyum (Na), Potasyum (K), Klor (Cl), Total bilirubin (Tot Bil), Direkt bilirubin (Dir Bil), Protein, Albumin, Aspartat Aminotransferaz (AST), Alanin Aminotransferaz (ALT), alkalen fosfataz (ALP), Laktat dehidrogenaz (LDH), Gama glutamil transferaz (GGT), Kalsiyum (Ca), Fosfor (P), Magnezyum (Mg)), kan grubu, operasyon günü (pre ve post operatif dönemde olmak), hastanın hastaneye başvurma

şikayetleri, kronik hastalığı, hastanın tanısı (Over ca, Serviks ca, Endometrium ca, Vulva ca), Patoloji sonucu (Grade 1, Grade 2, Grade 3, Grade 4), yapılan ameliyat (TAH+BSO (Total Abdominal Histerektomi + Bilateral Salpingooferektomi), PLND (Pelvik Lenf Nodu Diseksiyonu), Hemivulvektomi, Rektum üzeri BX (rektum üzeri biyopsi), Apendektomi, Frozen, Bridektomi, Diyafragma Altı Periton Rezeksiyonu, Salpenjektomi, Kolon onarımı, Wertheim, Omentektomi) alındı.

Bağımlı değişkenler: Jinekonkolojik kanser tanısı almış olması.

3.4. Araştırmanın Evreni ve Örneklemi

Araştırmanın evrenini, Pamukkale Üniversitesi Hastanesinde 2015-2021 yılları arasında Jinekolojik kanser tanısı almış 1130 hastadan oluşmaktadır.

Araştırmanın örneklemini, Jinekolojik kanser tanısı alıp kanser tedavisi için çeşitli ameliyatlı olmuş veya olacak olan 304 hastaya hemşirelik tanılarının konulması sonucunda makine öğrenimi ve veri madenciliği yöntemiyle geliştirilip belirlenmiştir.

3.4.1. Örneklem özellikleri

Örnekleme dahil edilme kriterleri

- 18 yaşından büyük olan bireyler
- Jinekolojik kanser tanısı almış olan
- Jinekolojik kanser tanısı aldıktan sonra tedavisi için gerekli ameliyatı geçirecek veya geçirmiş olan hastalar
- Bağımsız değişkenlerde belirtilen hasta verileri, eksiksiz olan kişiler araştırma kapsamına dahil edilmiştir.

Örneklemin dahil edilmeme kriterleri

- Jinekonkolojik tanı dışında kanser tanısı ve tedavisi almış olan kadın hastaların verileri

- Hemşirelik tanısı koyabilmesi için günü birlik yatan, kemoterapi alabilmek için günü birlik kalan hastalar ve eksik verisi olan veya taburcu olmuş hastalar çalışma dışında bırakılmıştır.
- Oluşturulan veri setine göre eksik verisi olan hastalar araştırma kapsamı dışında tutulmuştur.
- . Ayrıca bazı hastalarda farklı şikayet veya durumlardan dolayı hastaneye yatış yapmışlardır. Bu hastalarda veri içeriğine göre elenmiş veya çalışmaya dahil edilmemiştir.

3.4.2. Örneklem büyüklüğünün hesaplanması

Pamukkale Üniversitesi Hastanesinde 2015-2021 yılları arasında Jinekolojik kanser tanısı almış tüm hastaların verileri elde edildikten sonra elde edilen 1130 hasta incelenmiştir. Jinekonkolojik kanser tedavisi için ameliyat olmayan hastalar çalışma dışında bırakılmıştır. Ayrıca oluşturduğumuz veri setine göre eksik veriye sahip olan hastalar çalışma dışında bırakılmıştır. Bu inceleme sonucunda 304 hastadan elde edilen bilgiler sonucunda her yatış günü tek tek girilerek 2035 satır oluşturulmuştur ve hepsi çalışmaya dahil edilmiştir. Her yatış gününe araştırmacılar tarafından ayrı ayrı hemşirelik tanısı konulduğu için 2035 satır verisi kullanılmıştır.

3.5. Verilerin Elde Edilme Basamakları

- Pamukkale Üniversitesi Hastanesinde 2015-2021 yılları arasında Jinekolojik kanser tanısı almış 1130 hastanın verilerinin incelenmesi
- Hemşirelik tanılarını etkileyebilecek faktörler, ilgili literatüre dayalı olarak araştırılması,
- Bu araştırma sonuçlarına göre girdi değişkenleri olarak entegre edilmek üzere hasta dosyalarından birincil ayırt edici faktörler seçilmesi
- Araştırmacılar tarafından hemşirelik tanılarının konulması,
- Hemşirelik tanısı koyabilmek için günü birlik yatan, kemoterapi alabilmek için günü birlik kalan hastalar ve eksik verisi olan veya taburcu olmuş hastalar çalışma dışında bırakılması

- Bu analizler neticesinde 304 hasta çalışmaya dahil edilmesi,
- Her yatış gününe arařtırmacılar tarafından ayrı ayrı hemřirelik tanısı konulduđu için 2035 satır verisi eldesi
- Yapay zeka algoritması için uygun programın seğıilmesi,
- Veri tabanına verilerin kaydedilmesi,
- Temizlenmesi ve dönüřtürülmesi,
- En uygun veri tabanı denenmesi ve seğıimi.

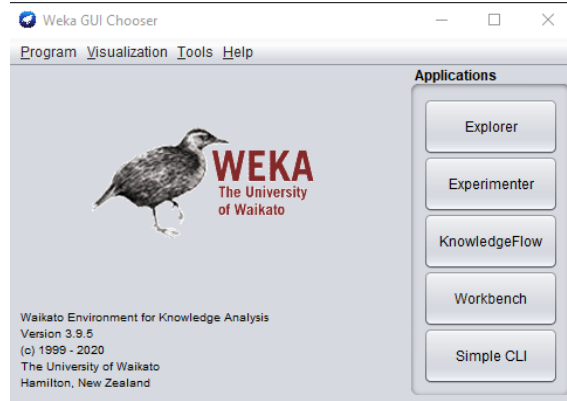
3.6. Yapay Zekanın Geliřtirilmesine Yönelik Uygulamalar

Arařtırmada yapay zekanın geliřtirilmesine yönelik uygulamalar; verilerin farklı formatlarda elde edilmesi, hemřirelik tanılarını etkileyebilecek faktörlerin belirlenmesi, ilgili literatüre dayalı olarak arařtırılması, verilerin tek bir formata dönüřtürülmesi, arařtırmacılar tarafından hemřirelik tanılarının konulması, verilerin temizlenmesi ve dönüřtürülmesi, uygun veri tabanının seğıimi için makine öğrenimi ve veri madenciliđi yöntemleri kullanılarak algoritmanın geliřtirilmesi yedi aşamadan oluşmaktadır.

3.6.1. Yapay zeka algoritmasının içeriđi

Zelanda'da bulunan Waikato Üniversitesi'nde GNU ve GPL lisansına sahip yazılım Weka isimli bir programdır. Veri tabanları açık kaynaklı olarak sunulmakta olan bu program ücretsiz ve halka açıktır. Bu sebepten dolayı kullanım olarak çok talep görmektedir. "Waikato Environment for Knowledge Analysis" ifadesinin baş harflerinden ismini edinmiřtir. Yeni Zelanda adalarında yařayan, soyu tükenmekte olan ve aynı zamanda uçamayan kuřtan ismini alan bu program Java tabanlıdır. Bu program hemen hemen birçok algoritmayı içinde barındırmaktadır. Ayrıca program veri madenciliđinin temelinde yer alan sınıflama, kümeleme ve birliktelik gibi işlemlerde çalışabilmektedir. Veri madenciliđinin tüm süreçlerine kapsamlı olarak destek sağlamaktadır. Birçok öğrenme algoritmasını sunmaktadır. Ayrıca ön işleme araçları içermektedir. Weka programında çeřitli görselleřtirme olanađı ve veri ön işleme araçları mevcuttur. Weka kullanımı için seğıilmiş olan veri kümesi için öğrenme yöntemlerinden birini uygulamak ve çıktı hakkında bilgi sahibi olabilmek için çıktıları analiz etmektedir. Bir başka seçenek ise yeni verilere iliřkin olasılıklar üretmek için daha önceden öğrenip ve kaydedilmiş olan modeli seğımek ve sonuçları üretmektedir. Birçok farklı öğrenme algoritmasını

uygulayarak performansları değerlendirip karşılaştırmak ise üçüncü bir yöntemdir. Bahsedilen algoritmalar ayarlanabilir özelliğe sahiptir (Aydemir 2019).



Şekil 3.1 Weka yazılımı ara yüzü

Bu bahsedilen program kullanılarak makine öğrenimi ve veri madenciliği yöntemi ile çalışılan yapay zeka algoritmasında veriler için en uygun veri tabanı denemesi yapılmıştır. Bu denemeler sonucunda MultilayerPerceptron veri tabanı seçilmiştir. Ayrıca karar ağaçları içinde J48 ya veri tabanı seçilmiştir.

3.6.2. Makine öğrenimi nedir?

İnsan davranışından biri olan öğrenmeyi taklit eden makine öğrenimi, veriler ve algoritmaları kullanarak doğruluğu aşamalı olarak arttıran bir bilgisayar bilimi dalıdır. Makine öğrenmesi terimi Arthur Samuel tarafından dama oyununda kullanıldığı bilinmektedir. Robert Nealey 1962 yılında makine öğrenimi ile geliştirilen yapay zekaya yenilmiştir. Şu an kullanılan teknolojileri düşünecek olursak 1962 yılındaki bu algoritma çok önemsiz kalmıştır. Ancak yapay zeka açısından bir dönüm noktası olarak kabul edilmektedir (IBM 2020).

Makine öğrenimi, bilgisayarların verilerden nasıl öğrendiğine odaklanan bilimsel disiplindir (Lip vd. 2010, O'Mahony vd. 2014). Verimli bilgi işlem algoritmasını imgeleyen bilgisayar bilimiyle verilerin bağıni öğrenmeye çalışan istatistiğin kesiştiği alanda ortaya çıkmaktadır. Matematik ve bilgisayar bilimiyle ilgili bahsedilen bu ilişki, milyarlarca veya trilyonlarca veri noktası içerebilen devasa veri kümelerinden oluşmaktadır. Bu durum istatistiksel modeller çıkarmanın benzersiz hesaplama zorlukları tarafından yürütülür.

Bilgisayarlar tarafından kullanılan öğrenme türleri çeşitli kategorileri içermektedir. Bunlar, denetimli öğrenme ve denetimsiz öğrenmedir (Deo 2015).

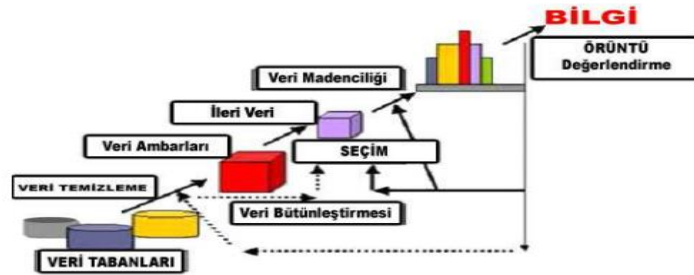
3.6.3. Veri madenciliği nedir?

Veri madenciliği, 1990'ların ortasında veri analizi ve bilgi keşfine farklı bir yaklaşım olarak ortaya çıkan nispeten yeni bir kavramdır. Amerika Birleşik Devletleri'nde (ABD) düzenlenen bir konferansta ilk defa bahsedilen veri madenciliği, 2010 Tıbbi Konu Başlıkları için tescil edilmiştir. Veri madenciliği esas olarak disiplinler arası bir alan olan istatistik ve makine öğrenimi boyutunda yapılan çalışmalardan oluşmaktadır. Veri madenciliği bu başlangıçlardan örüntü tanıma, veri tabanı tasarımı, yapay zeka, görselleştirme vb. içerecek şekilde ilerlemiştir. Milli İstihbarat Teşkilatı'nın (MIT) 2001'de teknoloji incelemesi, veri madenciliğini dünyayı değiştirecek yeni gelişen on teknolojiden biri olarak tanımlamıştır (MIT 2001).

Bilgisayar yazılım-donanımı ve internet teknolojisinin hızla gelişmesiyle birlikte veri miktarı inanılmaz bir hızla artmıştır. Soyut bir kavram olarak “büyük veri” şu anda hayatın her alanını etkilemektedir. Önemi kabul edilmiş olmasına rağmen, tanımı alandan alana değişiklik göstermektedir (Herland vd. 2014). Bilgisayar bilimi alanında, büyük veri; geleneksel bilgisayarlı tomografi (BT) ve yazılım ve donanım araçları kullanılarak kabul edilebilir bir süre içinde algılanamayan, elde edilemeyen, yönetilemeyen, işlenemeyen veya sunulamayan bir veri kümesini ifade edilmektedir (Wang vd. 2014, Herland vd. 2014).

Veri madenciliği tanımı; “Veri Madenciliği, veriler hakkında örtük, daha önce bilinmeyen ve potansiyel yararlı bilgilerin önemsiz bir şekilde çıkarılmasıdır” (Taşcı ve Şamlı 2020). Verilerin içerisinde saklı olan bilgiyi açığa çıkarmak veri madenciliği tekniğidir. Verilerin içerisinde hangisinin gerekli olduğunu tespit etmek oldukça önemlidir. Veriler genellikle farklı sistemlerde veya farklı formatlar şeklinde bulunur. Bu sebeplerden dolayı ilk yapılması gereken adım verilerin temizlenmesi ve düzenlenmesi işlemi olmalıdır. Bu amaçlara hizmet etmek doğrultusunda kurulan veri ambarının kurucusu W.H. Immon'a göre; verinin temizlenmesi, birleştirilmesi ve yeniden düzenlenmesi basamaklarından oluşan entegre bir depodur (Kızılkaya Aydoğan vd. 2006, Restivo 1999). Amaca ulaşmak için seçilmiş en doğru tabanda birleştirilen veriler örüntülü bir biçimde değişik metotlarla işlenir. Ortaya çıkmış olan birbiriyle alakalı, işlenmiş olan sağlıklı veriler amacına uygun kullanılmak üzere hazırdırlar. Bu büyük, gizli ve ham veri gruplarının faydalı bilgilere dönüştürülmesi ve daha sonra analiz edilmesi

işlemi program ve tekniklerle otomatik olarak yapılmakta ve teknolojinin verdiği yetkiye dayanarak birçok alanda fayda sağlamaktadır (Taşcı ve Şamlı 2020).



Şekil 3.2 Veri madenciliğinin aşamaları (Baykal 2006).



Şekil 3.3 Veri madenciliği ve iş zekası (Koyuncugil ve Özgülbaş 2009).

Şekil 3.2' de veri madenciliğiyle ilişkili basamaklar (Baykal 2006). Şekil 3.3' de ise veri kaynağı ile karar arasındaki ilişki gösterilmiştir (Koyuncugil ve Özgülbaş 2009).

3.6.4. Yapay zeka nedir?

İnsan beyni çalışma mekanizması bilim dünyasında uzun zamandır araştırma konusu olmuştur. Beynin işlem mekanizması, vermiş olduğu tepkiler gibi konular araştırılarak çalışma işleyişi ile ilişkili sorulara cevaplar aranmıştır (Doğan 2002). Bir grup bilgisayar bilimcisi 1956 yılında, bilgisayarların düşünmeye ve akıl yürütmeye programlanabileceğini öne sürmüştür.

Öğrenme eylemin her boyutu veya zekanın diğer herhangi bir özelliği, bir makine tarafından simüle edilerek keskin bir şekilde tanımlanabilir (Choi 2020). Bu düşünce ile beynin göstermiş olduğu işlevleri taklit ederek matematiksel bağlantılar ile birleştirilip bilgisayar programları ortaya çıkmaya başlamıştır. Zamanla gelişim gösteren bu bilim alanı yapay zeka adını almıştır (Deperlioğlu ve Köse 2011). Basitçe ifade etmek gerekirse yapay zeka, normalde insanlar tarafından gerçekleştirilen entelektüel görevleri otomatikleştirmeye odaklanan bir alandır. Makine öğrenimi ve derin öğrenme bu hedefe ulaşmanın özel yöntemleridir (Choi 2020).




Şekil 3.4 Seçilmiş veri bilimi tekniklerinin şeması (Choi 2020).

Şekil 3.4' de gösterildiği gibi Yapay zeka, veri bilimi alanına girer ve klasik programlama ile makine öğrenimini içerir. Makine öğrenimi, derin öğrenme ve yapay sinir ağları dahil olmak üzere birçok model ve yöntem içerir (Choi 2020).

3.6.5. Yapay sinir ağları

Yapay sinir ağları (YSA), biyolojik sinir ağlarından ilham alan bir makine öğrenme algoritmasıdır. Her YSA, diğer düğümlerle bağlantılar yoluyla iletişim kuran (aksonlara ve dendritlere benzer) düğümler (hücre gövdelerine benzer) içerir (James vd. 2013, Hastie vd. 2009). İnsan beyninin çalışma mekanizması gibi olan YSA kendi içerisinde bir hafızaya sahip olan paralel bilgi işleme sistemidir. Başka bir tanıma göre ise biyolojik ağ yapısını taklit etmek üzere hazırlanmış bir bilgisayar yazılımıdır (Elmas 2003). İnsan beyin işlevini örnek alan bu algoritma öğrenme, yeni bilgiler oluşturma, bilgileri keşfetmek gibi işlevleri yapabilmesi için geliştirilmiş bir algoritma olarak tanımlanmaktadır (Öztemel 2003). Warren McCulloch ve Walter Pitts tarafından YSA modeli ilk defa 1943 yılında

ortaya atılmıştır (Yapay sinir ağları). Biyolojik sinir ağlarını taklit eden YSA derinden incelendiği zaman, Şekil-1'de de görüldüğü gibi her bir yapının karşılığı olduğu görülmektedir (Eğrioğlu vd. 2009).



Şekil 3.5 Biyolojik sinir hücre ve yapay sinir ağları yapısı (Martarollo vd. 2013).

Biyolojik sinir ağlarının her bir yapısı YSA'nın da karşılık bulmaktadır. Bu durum Tablo-2 de gösterilmiştir. Örneğin biyolojik sinir sistemindeki Nöron yapısı YSA'ların da işlemci elemanı yapısına karşılık gelmektedir.

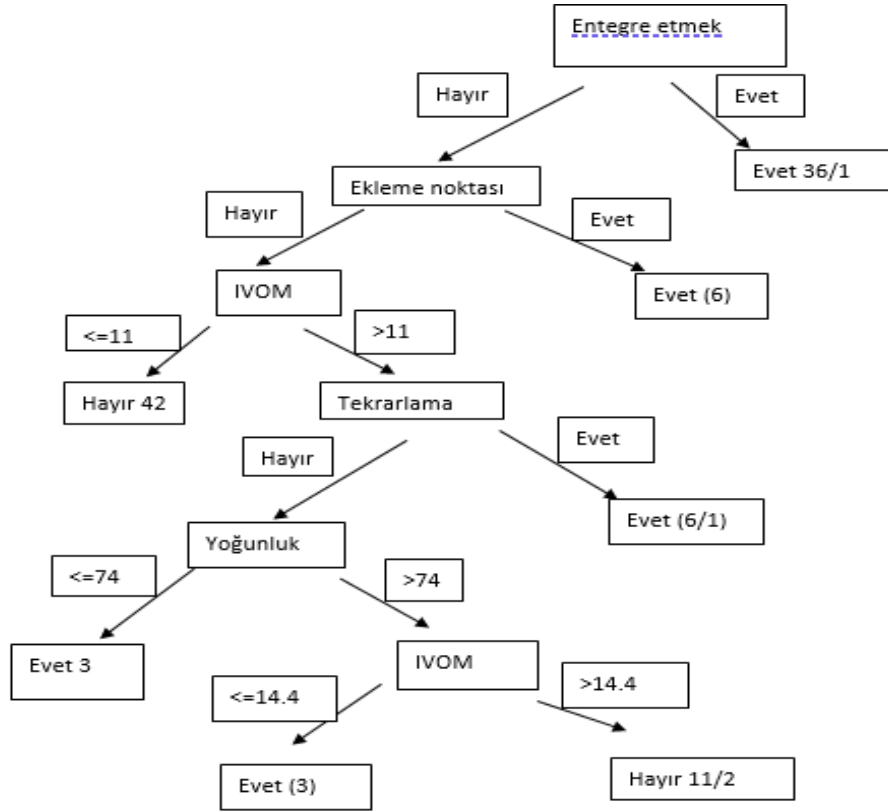
Biyolojik Sinir Sistemi	Yapay Sinir Sistemi
Nöron	İşlemci Elemanı
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Yapay Nöron Çıkışı
Sinapslar	Ağırlıklar

Şekil 3.6 Biyolojik sinir sistemi elemanları ve yapay sinir sisteminde karşılıkları (Martarollo vd. 2013).

Yapay sinir ağları başka isimlerde paralel dağıtılmış ağlar, bağlantılı ağlar, nuromorfik ağlar gibi adlarla da bilinmektedir (Keskenler vd. 2017).

3.6.6. Sınıflandırma ve karar ağaçları

Veri madenciliğinin en tanınmış işi sınıflandırmadır. Sınıflandırma, verilerin önceden belirlenmiş çıktılarına göre ayrıştırılmasını sağlayan bir tekniktir (Giudici 2003). Girdilerin çeşitli yöntemler ile model tarafından sınıflara atanma işlemidir. Edilmiş bilgilerin hangi sınıfa atanacağını veya atanmayacağını belirleyen süreçtir. Başka bir deyişle nesnelere veya durumlar için sınıfların belirlenmesidir. Sınıflandırma girdileri, her biri bir sınıf yaftasıyla ile yaftalanacak olan bir eğitim gözlem veya örnek setidir. Sınıflandırma çıktıları ise, modelin niteliklere dayalı olarak her bir gözleme atadığı sınıf etiketidir. Sınıflandırma işlemi makine öğrenme basamaklarının elzem durumlarından biridir. Tümevarımsal öğrenmenin temel yapısını, eğitim numunelerinden oluşan bir eğitim seti ve test numunelerinden oluşan bir test seti içermektedir. Sınıflandırma iki aşamadan oluşur ilki verilerin eğitimidir. Diğer aşama ise modelin test edilmesidir. Eğitim aşamasında modelin oluşturulması yapılmaktadır. Test aşamasındaysa test için ayrılan verilerle oluşturulan modelin kesinliğinin kontrol edilme basamağıdır. Test aşaması gerçekleştirildikten sonra doğru sınıflandırma oranına kesinlik oranı denmektedir. Sınıflandırma teknikleri; lojistik regresyon, diskriminant analizi, karar ağaçları, duruma dayalı uslamlama, Bayesgil sınıflayıcıları, eğer-sonra kuralları (kural çıkarımı), diğer mantıksal formüller yapay sinir ağları, bulanık kümeler, kaba kümeler ve benzerleri oluşturmaktadır (Emel ve Taşkın 2005). Karar ağacı sınıflandırması, en yaygın kullanılan makine öğrenme yöntemlerinden biridir. Bir karar ağacı sınıflandırma modeli, her bir iç düğümün bir özellik testini temsil ettiği, her dalın olası test sonuçlarından birini temsil ettiği ve her yaprak düğümün sınıflandırmayı temsil ettiği ağaç benzeri bir yapıyı göstermektedir (Che vd. 2010).



Şekil 3.7 Karar ağacı modeli (Che 2010).

Strepococcus'un genomik ada sınıflandırması için bir karar ağacı modeli örneği. Her bir iç düğüm özelliklerinden biridir örneğin; Yoğunluk, ekleme noktası, integraz, IVOM ve tekrar, her bir yaprak düğüm ise sınıflandırmadır yani "evet" test dizini segmentinin GI olduğunu "hayır" ise bir nonGI'dir.

3.7. Veri Toplama Aşaması

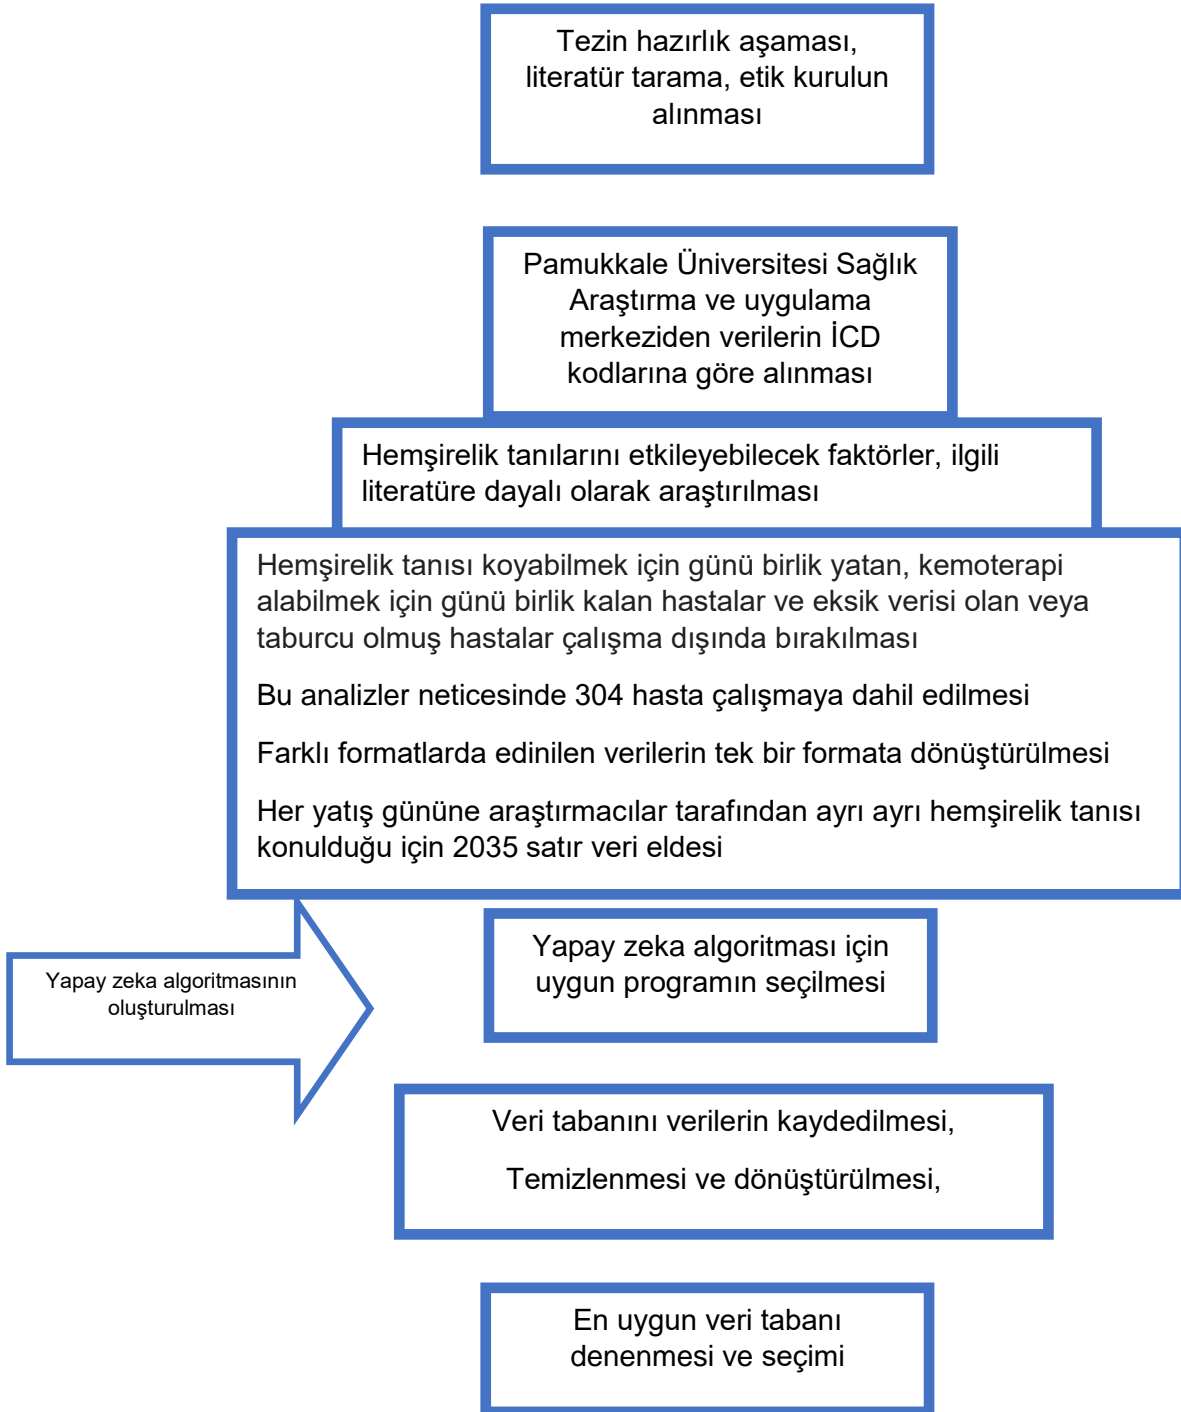
Araştırmanın verileri Pamukkale Üniversitesi Hastanesi Bilgi İşlem Koordinatörlüğüne 65124556-600-81282 Sayılı etik kurul belgesi ile başvurularak veriler elde edilmiştir. Veri tabanından International Classification of Disease (İCD) kodları ile jinekolojik tanı almış bireylere uygulanan işlem bilgileri alınmıştır.

3.8. Arařtırmanın Etik Yönu

Arařtırmaya bařlamadan önce Pamukkale Üniversitesi Giriřimsel Olmayan Klinik Arařtırmalar Etik Kurulu'ndan 01.06.2021 tarihli ve 11 sayılı onay alınmıřtır (Protokol no: E-60116787-020-60633) (EK1)

Etik kurul izninin alınmasının ardından Pamukkale Üniversitesi Saęlık Arařtırma ve uygulama merkeziden 02.07.2021 tarihinde elden alınmıřtır. (Protokol No: E-65124556-600-81282) (EK2)

Araştırmanın Aşamaları



Şekil 3.8 Araştırmanın aşamaları

Araştırma Sürecinde Yapılan Çalışmalar	Mart-Nisan2021	Mayıs 2021	Haziran 2021	Temmuz 2021	Ağustos- Aralık 2021	Ocak- Ekim 2022	Kasım- Aralık 2022	Ocak 2023
Literatür Tarama ve Konu Seçimi	✓							
Etik Kurul		✓						
Tez Önerisi			✓					
Verilerin elde edilmesi				✓				
Hemşirelik tanılarını etkileyebilecek faktörlerle ilgili literatür taraması					✓			
Tarama sonuçlarına göre verilerin seçilimi ve araştırmacılar tarafından hemşirelik tanılarının konulması						✓		
Yapay zeka algoritması için program seçilmesi ve oluşturulması							✓	
Tez Savunması								✓

Şekil 3.9 Araştırma sürecinde yapılan çalışmaların zamana göre dağılımı

3.9. Araştırmanın Sınırlılıkları

Tıbbi ve hemşirelik verilerinin otomasyon sistemindeki eksik girilmesinden dolayı çoğu veri çalışmada kullanılamamıştır. Hemşirelik tanısı için eksik veri olması bu çalışmanın sınırlılıklarını oluşturmaktadır. Bu sebepten dolayı eksik girilmemiş veriler ele alınarak hemşirelik tanısı konulmuştur.

3.10. İstatiksel Analiz

Weka programı kullanılarak veri madenciliği yöntemi ile çalışılan yapay zeka algoritmasında veriler için en uygun veri tabanı denemesi yapılmıştır. Bu denemeler sonucunda MultilayerPerceptron yapay zeka algoritması seçilmiştir. Ayrıca karar ağaçları içinde J48 yza seçilmiştir. Bu programın seçilme sebebi günümüzde çok tercih edilen ve Java platformu üzerinde geliştirilmiş açık kodlu bir yazılım olmasıdır. Bütün işletim sistemleriyle uyumu sebebi ile de bu program tercih edilmektedir (Aydemir 2019).

3.10.1. Veri toplama

Veri madenciliğinin ilk basamağı veri toplamadır. Pamukkale Üniversitesi Hastanesinin Bilgi işlem biriminden İCD kodları;

C51 Vulva malign neoplazmı kodu içerisinde;

- C51.0 Labium majus malign neoplazmı,
- C51.1 Labium minus malign neoplazmı,
- C51.2 Klitoris malign neoplazmı,
- C51.8 Vulva overlapping lezyonu,
- C51.9 Vulva malign neoplazmı, tanımlanmamış,

C52 Vajina malign neoplazmı

- C53 Serviks uteri malign neoplazmı kodu içerisinde;
- C53.0 Endoserviks malign neoplazmı,
- C53.1 Ekzoserviks malign neoplazmı,
- C53.8 Serviks uteri overlapping lezyonu,
- C53.9 Serviks uteri malign neoplazmı, tanımlanmamış,

C54(Korpus uteri malign neoplazmı) kodu içerisinde;

- C54.0 (İstmus uteri malign neoplazmı),
- C54.1 (Endometrium malign neoplazmı),
- C54.2 (Miyometrium malign neoplazmı),
- C54.3 (Fundus uteri malign neoplazmı),
- C54.8 (Korpus uteri overlapping lezyonu),
- C54.9 (Korpus uteri malign neoplazmı, tanımlanmamış),

C55 Uterus malign neoplazmı, tanımlanmamış kısım,

C56 (Over Maning Neoplazi),

C57 Kadın genital organları malign neoplazmı, diğer ve tanımlanmamış kodu içerisinde;

- C57.0 Fallop t p  malign neoplazmı,
- C57.1 Geniř ligament malign neoplazmı,
- C57.2 Yuvarlak ligament malign neoplazmı,
- C57.3 Parametrium malign neoplazmı,
- C57.4 Uterus adneksleri malign neoplazmı, tanımlanmamıř,
- C57.7 Kadın genital organları malign neoplazmı,
- C57.8 Kadın genital organlarının overlapping lezyonu,
- C57.9 Kadın genital organı malign neoplazmı, olan hastaların bilgileri sistemden ekilmiřtir.

Bilgi iřlem servisinden bu kodlar kullanılarak hastalara yapılan kan testleri, Epikrizleri, Ameliyat y ntem ve řekilleri, Patoloji raporları, sistemden elde edilmiřtir. Bu elde edilen bilgiler veri kaynađı olarak kullanılmıřtır.

3.10.2. Veri tabanına verilerin kaydı

Jinekonkolojik tanı alıp ameliyat olmuř veya olacak hastalar alıřmaya dahil edilmiřlerdir. Verilerde hemřirelik tanılarını etkileyebilecek fakt rlerle ilgili literat re dayalı olarak arařtırılmıřtır. Bu arařtırmanın ardından girdi deđiřkenleri olarak entegre edilmek  zere hasta dosyalarından birincil ayırt edici fakt rler seilmiřtir. Seilen fakt rler baz alınarak hastaların ameliyat durumlarıyla iliřkili yatıř g nleri; ameliyat  ncesi preoperatif ameliyat sonrası postoperatif olmak  zere gruplara ayrılmıřtır. Ayrıca hastanın hastanede kalıř s releri de belirtilmiřtir. Tanıları etkileyen diđer fakt rlerde d ř n lerek veri girdileri oluřturulmuřtur. Ayrıca bazı hastalarda farklı řikayet veya durumlardan dolayı hastaneye yatıř yapmıřlardır. Bu hastalarda veri ieriđine g re elenmiř veya alıřmaya dahil edilmemiřtir. Bu ayırma iřleminden  nce 1130 hasta var iken 304 hastanın verileri alıřmaya dahil edilmiřtir. Sonu olarak 304 hasta veri madenciliđi iřleminde kullanılmak  zere hazırlanmıřtır. Ayrıca her yatılan g n farklı bir hasta olarak kabul edilerek 2035 veri  zerinde iřlem yapılmıřtır.

Kan Testleri İerisinde

1.HGB, 2. INR, 3.Glukoz, 4. Bun, 5. re, 6.Kreatinin, 7. Na, 8.K, 9.Cl, 10. Tot Bil, 11. Dir Bil, 12.Protein, 13.Albumin, 14. AST, 15. ALT, 16. ALP, 17. LDH, 18. GGT, 19. Ca, 20. P, 21. Mg ve kan grubu deđerleri alınmıřtır.

Hastanın ICD kodlarına göre patoloji sonuçlarına göre hastalığının hangi evrede olduğu, yapılan ameliyat, preoperatif veya postoperatif kaçınıcı gününde olduğu, hastaneye hangi şikâyet ile başvurduğu, kronik hastalıkları alınmıştır.

3.10.3. Veri temizleme

Hemşirelik tanısı koyabilmek için günü birlik yatan, kemoterapi alabilmek için günü birlik kalan hastalar ve eksik verisi olan veya taburcu olmuş hastalar çalışma dışında bırakılmıştır. Hemşirelik tanılarını etkileyebilecek faktörler, ilgili literatüre dayalı olarak araştırılmıştır (Wilkinson ve Barcus 2018). Bu araştırma sonuçlarına göre girdi değişkenleri olarak entegre edilmek üzere hasta dosyalarından birincil ayırt edici faktörler seçilmiştir.

3.10.4. Veri dönüştürme

Verilerin sisteme işlenmesi için dönüştürülmesi gerekmektedir (Aydemir 2019). Veri madenciliğinde veriler sayısal, metinsel isimler veya seçimli (nominal) şekilde olması gerekir. Bu sebepten dolayı edinilmiş veya temizlenmiş olan veriler aşağıdaki belirtilen isim ve şekle dönüştürülmüştür.

1. Cinsiyet tüm verilerde aynı silindi
2. Hasta No silindi (Her bir durum ayrı hasta olarak kabul edildi)
3. Yaş; Hastanın sayısal olarak yaşı
4. Hastaneye yatış yılı; Sayısal olarak yatış yılı
5. HGB, INR, Glukoz, Bun, Üre, Kreatinin, Na, K, Cl, Tot Bil, Dir Bil, Protein, Albumin, AST, ALT, ALP, LDH, GGT, Ca, P, Mg; Sayısal değer olarak sonucu
6. Mg değerlerinden bir veri 4035 dir. Değeri aralığın çok üzerinde olmasından dolayı silinmiştir.
7. Kan grubu metinsel: A, B, AB, O
8. RH değeri metinsel: Negatif, Pozitif
9. Operasyon günü; preoplar (-), postoplar (+) olarak sayısal değere dönüştürülmüştür-1,0,1,2...
10. Hastanın hastaneye başvurma şikayetleri seçimli değer olarak alınmıştır
 - Kanama: var ya da yok,
 - Ağrı: var ya da yok,

- Yorgunluk: var ya da yok,
- Abdomende şişlik: var ya da yok,
- HPV Pozitif: var ya da yok
- Kilo kaybı: var ya da yok

11. Kronik hastalığı metinsel olarak girilmiştir

- Ülser, Dm, Ht, Guatr, Astım, Stres İnkontinansı, İşitme Kaybı, Fibromiyalji, Panik Atak, Parkinson, Reflü, Kalp, Epilepsi, Obez, Depresyon, Koah, Böbrek Yetmezliği

12. Hastalık tanısı; metinsel olarak girilmiştir

- Over ca, Serviks ca, Endometrium ca, Vulva ca

13. Patoloji metinsel olarak girilmiştir

- Grade 1, Grade 2, Grade 3, Grade 4

14. Yapılan ameliyat metinsel olarak girilip gruplara ayrıldı

- TAH+BSO
- PLND
- Hemivulvektomi
- Rektum Üzeri BX
- Apendektomi
- Frozen
- Bridektomi
- Diyafragma Altı Periton Rezeksiyonu
- Salpenjektomi
- Kolon Onarımı
- Wertheim
- Omentektomi

15. Solunum Desteği; var ya da yok

16. Diyare tüm hastalarda yok, silindi

17. Uyku örüntüsünde bozulma hemşirelik tanısı tüm hastalarda olduğu için silindi

18. Enfeksiyon riski hemşirelik tanısı tüm hastalarda olduğu için silindi

19. Ayrıca düzeni bozan veya hatalı giriş olduğu tahmin edilen veriler silindi

Bu aşamada veri dönüştürme süreci tekrarlanmış veri dönüştürme kısmı en iyi performansla oluşturulmuştur.

3.10.5. Öznitelik Analizi

Veri silme ve dönüştürme aşamasından sonra modelleme veya model oluşturma aşaması gerçekleştirilmektedir (Aydemir 2019). Veri madenciliği yazılımlarından kullanılan WEKA programında uygun veri formatının oluşturulması sağlanmıştır. Verilerin toplanması işlenmesi, temizlenmesi ve dönüştürülmesinden sonra oluşan durumlar aşağıdaki Şekil- ve Şekil- de gösterilmektedir.

- HGB(12-16) numeric
- ' INR(0.85-1.2)' numeric
- Glukoz(75-105) numeric
- BUN(6-20) numeric
- Üre(15-40) numeric
- Kreatinin(0.6-1.1) numeric
- Na(136-145) numeric
- K(3.4-4.5) numeric
- Cl(98-107) numeric
- 'Tot Bil(0.2-1.2)' numeric
- 'Dir Bil(0-0.5)' numeric
- Protein(6.4-8.3) numeric
- Albumin(3.5-5) numeric
- Ast(5-35) numeric
- Alt(0-55) numeric
- alp(40-450) numeric
- LDH(125-243) numeric
- GGT(9-36) numeric
- Ca(8.9-10) numeric
- P(2.3-4.7) numeric
- Mg(1.6-2.6) numeric
- GÜN numeric
- sikayet_kanama {var,yok}
- sikayet_agrı {yok,var}
- sikayet_yorgunluk {yok,var}
- sikayet_abdomensiskinlik {yok,var}
- 'HPV Pozitif' {yok,var}
- 'kilo kaybı' {yok,var}
- 'KAn gruBu' {B,A,AB,O}
- RH {pozitif,negatif}
- astım {yok,var}
- dm {yok,var}
- ht {yok,var}
- böbrek {yok,var}
- guatr {yok,var}
- işitme {yok,var}
- epilepsi {yok,var}
- fibromialji {yok,var}
- 'panik atık' {yok,var}
- kalp {yok,var}
- obez {yok,var}
- depresyon {yok,var}
- koah {yok,var}
- ulser {yok,var}
- parkinson {yok,var}
- reflü {yok,var}
- 'stres inkontinansı' {yok,var}
- tanı ('endometrium ca ','over ca','serviks ca','vulva ca')
- Patoloji {'grade 2','grade 3','grade 1','grade 4'}
- 'APENDEKTOMI' {hayir,evet}
- BRİDEKTOMI {hayir,evet}
- 'DIAFRAGMA ALTI PERİTON REZEKSİYONU' {hayir,evet}
- 'FROZEN' {hayir,evet}
- HEMİVULVEKTOMİ {hayir,evet}
- OMENTEKTOMİ {hayir,evet}
- PLND {evet,hayir}
- REKTUMÜZERİBX {hayir,evet}
- REZEKSİYON {hayir,evet}
- SAĞUSO {hayir,evet}
- 'SALPENJEKTOMİ' {hayir,evet}
- 'SIGMOİDKOLONONARİMİ' {hayir,evet}
- SOLOOFEREKTOMİ {hayir,evet}
- SOLWEDGE {hayir,evet}
- SSA {hayir,evet}
- 'TAH+BSO' {evet,hayir}
- 'WERTHEİM' {hayir,evet}
- 'kan takılma durumu' {yok,var}
- Y_tansiyon {yok,var}
- 'Ameliyat sonrası oluşan durumlar' {kabızlık,yok,'mesane injury','yüksek şeker','sanrı.ateş','solunum yolu alerjisi','idrar çıkışı yok'}
- tanı_Konstipasyon {var,yok}
- 'tani_Stres inkontinansı' {yok,var}
- 'tani_Banyo yapmada özbakım yetersizliği' {var,yok}
- 'tani_Beslenmede özbakım yetersizliği' {var,yok}
- 'tani_Giyinmede özbakım yetersizliği' {var,yok}
- 'tani_Tuvalet ihtiyacını karşılamada özbakım yetersizliği' {var,yok}
- 'tani_Beden imajında bozulma' {yok,var}
- 'tani_Sözel iletişimde bozulma' {yok,var}
- 'tani_Acı çekme, infertilite riskine bağlı' {yok,var}
- 'tani_Aspirasyon riski' {yok,var}
- 'tani_Kanama riski' {var,yok}
- 'tani_Kan şekeri düzeyinde dengesizlik riski' {yok,var}
- 'tani_düşme riski' {var,yok}
- 'tani_Gastrointestinal motilitede bozulma riski' {yok,var}
- 'tani_Kardiyovasküler fonksiyonda bozulma riski' {yok,var}
- 'tani_Cerrahi iyileşmede geçikme riski' {var,yok}
- 'tani_Doku bütünlüğünde bozulma riski' {var,yok}
- 'tani_karaciğer fonksiyonunda bozulma riski' {yok,var}

Şekil 3.10 Veri temizleme işlemi sonrası ve veri dönüştürülmesi sonrası durum

Weka programı kullanılarak veri madenciliği yöntemi ile çalışılan yapay zeka algoritmasında veriler için en uygun veri tabanı denemesi yapılmıştır. Bu denemeler sonucunda MultilayerPerceptron veri tabanı seçilmiştir. Ayrıca veri madenciliği uygulaması için en başarılı olan karar ağaçları algoritmalarından J48 algoritması seçilmiştir.

4.BULGULAR

Yapılan çalışma sonrası bulgular iki ayrı kategoriye ayrılmıştır. Toplamda 17 hemşirelik tanısı elde edilmiştir. Uyku örüntüsünde bozulma ve enfeksiyon riski tanısı tüm hastalarda olduğu için makine öğrenimi ve veri madenciliği tekniği ile veri dönüştürme basamağında silinmiştir.

4.1. Makine Öğrenmesi bulguları

Araştırmanın sonucunda çıkan algoritmalar tablolarda gösterilmiştir:

- Banyo Yapmada Özbakım Yetersizliği tanısına ilişkin makine öğrenmesi bulguları
- Beslenmede Özbakım Yetersizliği tanısına ilişkin makine öğrenmesi bulguları
- Tuvalet İhtiyacını Karşılamada Özbakım Yetersizliği tanısına ilişkin makine öğrenmesi bulguları
- Giyinmede Özbakım Yetersizliği tanısına ilişkin makine öğrenmesi bulguları
- Konstipasyon tanısına ilişkin makine öğrenmesi bulguları
- Beden İmajında Bozulma tanısına ilişkin makine öğrenmesi bulguları
- Sözel İletişimde Bozulma tanısına ilişkin makine öğrenmesi bulguları
- Stres İnkontinansı tanısına ilişkin makine öğrenmesi bulguları
- Cerrahi İyileşmede Gecikme Riski Tanısına ilişkin makine öğrenmesi bulguları
- Doku Bütünlüğünde Bozulma Riski tanısına ilişkin makine öğrenmesi bulguları
- Düşme Riski tanısına ilişkin makine öğrenmesi bulguları
- Gastrointestinal Mobilitede Bozulma Riski tanısına ilişkin makine öğrenmesi bulguları

- Kan Şekeri Düzeyinde Dengesizlik Riski tanısına ilişkin makine öğrenmesi bulguları
- Kanama Riski tanısına ilişkin makine öğrenmesi bulguları
- Karaciğer Fonksiyonunda Bozulma Riski tanısına ilişkin makine öğrenmesi bulguları
- Kardiyovasküler Fonksiyonda Bozulma Riski tanısına ilişkin makine öğrenmesi bulguları
- Aspirasyon Riski tanısına ilişkin makine öğrenmesi bulguları

4.1.1. Banyo yapmada özbakım yetersizliği tanısına ilişkin makine öğrenmesi bulguları

Bu bölümde NANDA'ya göre banyo yapmada özbakım yetersizlik tanısının konulmasında ilişkili olan verilerin Üre, Cl, Albumin, Alt, Ca, hastanın hastaneye yattığı gün, ameliyat biçimlerinden; Pelvik Lenf Nodu Diseksiyonu, ameliyat biçimlerinden; Total Abdominal Histerektomi + Bileteral Salpingooferektomi ilişkili olduğu makine öğrenmesi ve veri madenciliği yöntemiyle bulunmuştur. Doğruluk oranı %99.5074' tur.

Tablo 4.1.1.1. Banyo yapmada özbakım yetersizliği tanısına ilişkin veriler ve doğruluk oranı tablosu

BANYO YAPMADA ÖZBAKIM YETERSİZLİĞİ

İlişkili Olan Veriler	Doğru Sınıflandırılmış Örnek Sayısı ve Oranı	Toplam Örnek Sayısı
Üre	404	406
Cl	%99.5074	
Albumin		
Alt		
Ca		
Hastanın Hastanede Yattığı Gün		
Ameliyat Biçimlerinden; Pelvik Lenf Nodu Diseksiyonu		
Ameliyat Biçimlerinden; Total Abdominal Histerektomi + Bileteral Salpingooferektomi		

4.1.2. Beslenmede özbakım yetersizliği tanısına ilişkin makine öğrenmesi bulguları

Bu bölümde beslenmede özbakım yetersizlik NANDA tanısının konulmasında ilişkili olan verilerin Üre, Cl, Albümin, Alt, hastanın hastaneye yattığı gün, ameliyat biçimlerinden; Pelvik Lenf nodu Diseksiyonu, ameliyat biçimlerinden; Total Abdominal Histerektomi + Bileteral Salpingooferektomi ilişkili olduğu makine öğrenmesi ve veri madenciliği yöntemiyle bulunmuştur. Doğruluk oranı %99.5074'tur.

Tablo 4.1.2.1. beslenmede özbakım yetersizliği tanısına ilişkin veriler ve doğruluk oranı tablosu

Beslenmede Özbakım Yetersizliği				
İlişkili Olan Veriler	Doğru	Sınıflandırılmış	Örnek	Toplam Örnek Sayısı
	Sayısı ve Oranı			
Üre	404			406
Cl	%99.5074			
Albümin				
Alt				
Ca				
Hastanın Hastanede Yattığı Gün				
Ameliyat Biçimlerinden; Pelvik Lenf Nodu Diseksiyonu				
Ameliyat Biçimlerinden; Total Abdominal Histerektomi + Bilateral Salpingooferektomi				

4.1.3. Tuvalet ihtiyacını karşılamada özbakım yetersizliği tanısına ilişkin makine öğrenmesi bulguları

Bu bölümde Tuvalet İhtiyacını Karşılamada Özbakım Yetersizlik NANDA Tanısının Konulmasında İlişkili Olan Verilerin Üre, Cl, Albümin, Alt, hastanın hastaneye yattığı gün, ameliyat biçimlerinden; Pelvik Lenf Nodu Diseksiyonu, ameliyat biçimlerinden; Total Abdominal Histerektomi + Bileteral Salpingooferektomi ilişkili olduğu makine öğrenmesi ve veri madenciliği yöntemiyle bulunmuştur. Doğruluk Oranı %99.5074'tur.

Tablo 4.1.3.1. Tuvalet ihtiyacını karşılamada özbakım yetersizliği tanısına ilişkin veriler ve doğruluk oranı tablosu

Tuvalet İhtiyacını Karşılamada Özbakım Yetersizliği			
İlişkili Olan Veriler	Doğru	Sınıflandırılmış Örnek	Toplam Örnek Sayısı
	Sayısı ve Oranı		
Üre	404		406
Cl	%99.5074		
Albumin			
Alt			
Ca			
Hastanın Hastanede Yattığı Gün			
Ameliyat Biçimlerinden; Pelvik Lenf Nodu Diseksiyonu			
Ameliyat Biçimlerinden; Total Abdominal Histerektomi + Bilateral Salpingooferektomi			

4.1.4. Giyinmede özbakım yetersizliği tanısına ilişkin makine öğrenmesi bulguları

Bu bölümde giyinmede özbakım yetersizlik NANDA tanısının konulmasında ilişkili olan verilerin üre, cl, albümin, alt, hastanın hastaneye yattığı gün, ameliyat biçimlerinden; pelvik lenf nodu diseksiyonu, ameliyat biçimlerinden; total abdominal histerektomi + bileteral salpingooferektomi ilişkili olduğu makine öğrenmesi ve veri madenciliği yöntemiyle bulunmuştur. Doğruluk oranı %99.5074'tur.

Tablo 4.1.4.1. Giyinmede özbakım yetersizliği tanısına ilişkin veriler ve doğruluk oranı tablosu

Giyinmede Özbakım Yetersizliği

İlişkili Olan Veriler	Doğru Sınıflandırılmış Örnek Sayısı ve Oranı	Toplam Örnek Sayısı
Üre	404	406
Cl	%99.5074	
Albümin		
Alt		
Ca		
Hastanın Hastanede Yattığı Gün		
Ameliyat Biçimlerinden; Pelvik Lenf Nodu Diseksiyonu		
Ameliyat Biçimlerinden; Total Abdominal Histerektomi + Bilateral Salpingooferektomi		

4.1.5. Konstipasyon tanısına ilişkin makine öğrenmesi bulguları

Bu bölümde konstipasyon tanısına ilişkin verilerin böbrek hastalığı bulunması, işitme kaybı, fibromiyalji, obez, reflü, stres inkontinansı, ameliyat biçimlerinden; Hemivulpektomi, ameliyat biçimlerinden; Rektum üzeri biyopsi, ameliyat biçimlerinden; Salpenjektomi ilişkili olduğu makine öğrenmesi ve veri madenciliği yöntemiyle bulunmuştur. Doğruluk oranı %99.2611'dir.

Tablo 4.1.5.1. Konstipasyon tanısına ilişkin veriler ve doğruluk oranı tablosu

Konstipasyon			
İlişkili Olan Veriler	Doğru	Sınıflandırılmış Örnek	Toplam Örnek Sayısı
	Sayısı ve Oranı		
Böbrek Hastalığı Bulunması	403		406
İşitme Kaybı	%99.2611		
Fibromiyalji			
Obez			
Depresyon			
Koah			
Reflü			
Stres İnkontinansı			
Ameliyat Biçimlerinden;			
Hemivulpektomi			
Ameliyat Biçimlerinden;			
Rektum Üzeri Biyopsi			
Ameliyat Biçimlerinden;			
Salpenjektomi			

4.1.6. Beden imajında bozulma tanısına ilişkin makine öğrenmesi bulguları

Bu bölümde Beden İmajında tanısına ilişkin veriler yaş, HGB, Alp, hastalık şikayeti; kanama, hastalık şikayeti; abdomen şişlik, hastalık şikayeti; kilo kaybı, patoloji sonucundan grade derecesi, ameliyat biçimlerinden; Apendektomi ilişkili olduğu makine öğrenmesi ve veri madenciliği yöntemiyle bulunmuştur. Doğruluk oranı %99.2611'dir.

Tablo 4.1.6.1. Beden imajında bozulma tanısına ilişkin veriler ve doğruluk oranı tablosu

Beden İmajında Bozulma			
İlişkili Olan Veriler	Doğru	Sınıflandırılmış Örnek	Toplam Örnek Sayısı
	Sayısı ve Oranı		
Yaş	403		406
HGB	%99.2611		
Alp			
Hastalık Şikayeti; Kanama			
Hastalık Şikayeti; Abdomen Şişlik			
Hastalık Şikayeti; Kilo Kaybı			
Grade Derecesi			
Ameliyat Biçimlerinden; Apendektomi			

4.1.7. Sözel İletişimde bozulma tanısına ilişkin makine öğrenmesi bulguları

Bu bölümde Sözel İletişimde Bozulma tanısına ilişkin veriler yaş, Rh, astım, guatr, işitme kaybı, ameliyat biçimlerinden; Frozen, yüksek tansiyon ilişkili olduğu makine öğrenmesi ve veri madenciliği yöntemiyle bulunmuştur. Doğruluk oranı %100'dür.

Tablo 4.1.7.1. Sözel iletişimde bozulma tanısına ilişkin veriler ve doğruluk oranı tablosu

Sözel İletişimde Bozulma				
İlişkili Veriler	Doğru	Sınıflandırılmış	Örnek	Toplam Örnek Sayısı
	Sayısı ve Oranı			
Yaş	406			406
Rh	%100			
Astım				
Guatr				
İşitme Kaybı				
Ameliyat		Biçimlerinden;		
Frozen				
Yüksek Tansiyon				

4.1.8. Stres inkontinansı tanısına ilişkin makine öğrenmesi bulguları

Bu Bölümde Stres İnkontinansı Tanısına ilişkin veriler yaş, Alp, hastalık şikâyeti; Abdomende şişlik, kan grubu, guatr, stres inkontinansı ile ilişkili olduğu makine öğrenmesi ve veri madenciliği yöntemiyle bulunmuştur. Doğruluk oranı %100'dür.

Tablo 4.1.8.1. Stres inkontinansı tanısına ilişkin veriler ve doğruluk oranı tablosu

Stres İnkontinansı				
İlişkili Veriler	Doğru	Sınıflandırılmış	Örnek	Toplam Örnek Sayısı
	Sayısı ve Oranı			
Yaş	406			406
Alp	%100			
Hastalık Şikayeti; Abdomende				
Şişlik				
Kan Grubu				
Guatr				
Stres İnkontinansı				

4.1.9. Cerrahi iyileşmede gecikme riski tanısına ilişkin makine öğrenmesi bulguları

Bu bölümde Cerrahi İyileşmede Gecikme Riski Tanısına ilişkin veriler yaş, Bun, hastanın hastanede yattığı gün, hastalık şikayeti; Abdomende şişlik, astım, Dm, Ht, epilepsi, reflü, ameliyat biçimlerinden; Bridektomi ile ilişkili olduğu makine öğrenmesi ve veri madenciliği yöntemiyle bulunmuştur. Doğruluk oranı %98.7685'tir.

Tablo 4.1.9.1. Cerrahi iyileşmede gecikme riski tanısına ilişkin veriler ve doğruluk oranı tablosu

Cerrahi İyileşmede Gecikme Riski			
İlişkili Veriler	Doğru	Sınıflandırılmış Örnek	Toplam Örnek Sayısı
	Sayısı ve Oranı		
Yaş	401		406
Bun	%98.7685		
Hastanın Hastanede Yattığı Gün			
Hastalık Şikâyeti; Abdomende Şişlik			
Astım			
Dm			
Ht			
Epilepsi			
Reflu			
Ameliyat Biçimlerinden; Bridektomi			

4.1.10. Doku bütünlüğünde bozulma riski tanısına ilişkin makine öğrenmesi bulguları

Bu bölümde Doku Bütünlüğünde Bozulma Riski tanısına ilişkin veriler yaş, Bun, albümin, hastanın hastanede yattığı gün, ameliyat biçimlerinden; Pelvik Lenf Nodu Diseksiyonu, ameliyat biçimlerinden; Total Abdominal Histerektomi + Bilateral Salpingooferektomi ili ilişkili olduğu makine öğrenmesi ve veri madenciliği yöntemiyle bulunmuştur. Doğruluk oranı %97.7833'tur.

Tablo 4.1.10.1. Doku bütünlüğünde bozulma riski tanısına ilişkin veriler ve doğruluk oranı tablosu

Doku Bütünlüğünde Bozulma Riski			
İlişkili Veriler	Doğru	Sınıflandırılmış Örnek	Toplam Örnek Sayısı
	Sayısı ve Oranı		
Yaş	397		406
Bun	%97.7833		
Albümin			
Hastanın Hastanede Yattığı Gün			
Ameliyat Biçimlerinden; Pelvik Lenf Nodu Diseksiyonu			
Ameliyat Biçimlerinden; Total Abdominal Histerektomi + Bilateral Salpingooferektomi			

4.1.11. Düşme riski tanısına ilişkin makine öğrenmesi bulguları

Bu bölümde Düşme Riski tanısına ilişkin veriler taş, Bun, hastanın hastanede yattığı gün, ameliyat biçimlerinden; Pelvik Lenf Nodu Diseksiyonu, ameliyat biçimlerinden; Total Abdominal Histerektomi + Bilateral Salpingooferektomi ile ilişkili olduğu makine öğrenmesi ve veri madenciliği yöntemiyle bulunmuştur. Doğruluk oranı %98.2759'tur.

Tablo 4.1.11.1. Düşme riski tanısına ilişkin veriler ve doğruluk oranı tablosu

Düşme Riski			
İlişkili Veriler	Doğru	Sınıflandırılmış Örnek	Toplam Örnek Sayısı
	Sayısı ve Oranı		
Yaş	399		406
Bun	%98.2759		
Hastanın Hastanede Yattığı Gün			
Depresyon			
Ameliyat Biçimlerinden; Pelvik Lenf Nodu Diseksiyonu			
Ameliyat Biçimlerinden; Total Abdominal Histerektomi + Bilateral Salpingooferektomi			

4.1.12. Gastrointestinal mobilitede bozulma riski tanısına ilişkin makine öğrenmesi bulguları

Bu bölümde Gastrointestinal Mobilitede Bozul Riski tanısına ilişkin veriler glukoz, hastanın hastanede yattığı gün, Koah, ülser, ameliyat biçimlerinden; Hemivulvektomi, ameliyat biçimlerinden; Pelvik Lenf Nodu Diseksiyonu, ameliyat biçimlerinden; Rektum Üzeri Biyopsi ili ilişkili olduğu makine öğrenmesi ve veri madenciliği yöntemiyle bulunmuştur. Doğruluk oranı %99.5074'tur.

Tablo 4.1.12.1. Gastrointestinal mobilitede bozulma riski tanısına ilişkin veriler ve doğruluk oranı tablosu

Gastrointestinal Mobilitede Bozulma Riski			
İlişkili Veriler	Doğru	Sınıflandırılmış	Örnek
	Sayısı ve Oranı	Örnek	Toplam Örnek Sayısı
Glukoz	404		406
Hastanın Hastanede Yattığı	%99.5074		
Gün			
Koah			
Ülser			
Ameliyat Biçimlerinden;			
Hemivulvektomi			
Ameliyat Biçimlerinden; Pelvik			
Lenf Nodu Diseksiyonu			
Ameliyat Biçimlerinden;			
Rektum Üzeri Biyopsi			

4.1.13. Kan Şekeri Düzeyinde Dengesizlik Riski tanısına ilişkin makine öğrenmesi bulguları

Bu bölümde Kan Şekeri Düzeyinde Dengesizlik Riski tanısına ilişkin veriler glukoz, Hpv pozitif, Dm, böbrek hastalığı bulunması, kalp hastalığı bulunması, fibromiyalji, obez, Parkinson, ameliyat biçimlerinden; Bridektomi, ameliyat biçimlerinden; Salpenjektomi ili ilişkili olduğu makine öğrenmesi ve veri madenciliği yöntemiyle bulunmuştur. Doğruluk oranı %94.335'tir.

Tablo 4.1.13.1. Kan şekeri düzeyinde dengesizlik riski tanısına ilişkin veriler ve doğruluk oranı tablosu

Kan Şekeri Düzeyinde Dengesizlik Riski			
İlişkili Veriler	Doğru	Sınıflandırılmış	Toplam Örnek Sayısı
	Sayısı ve Oranı	Örnek	
Glukoz	383		406
Hpv Pozitif	%94.335		
Dm			
Böbrek Hastalığı Bulunması			
Kalp Hastalığı Bulunması			
Fibromiyalji			
Obez			
Parkinson			
Ameliyat		Biçimlerinden;	
Bridektomi			
Ameliyat		Biçimlerinden;	
Salpenjektomi			

4.1.14. Kanama riski tanısına ilişkin makine öğrenmesi bulguları

Bu bölümde Kanama Riski tanısına ilişkin veriler üre, Cl, Albumin, Alt, Ca, hastanın hastanede yattığı gün, ameliyat biçimlerinden; Pelvik Lenf Nodu Diseksiyonu, ameliyat biçimlerinden; Total Abdominal Histerektomi + Bilateral Salpingooferektomi ile ilişkili olduğu makine öğrenmesi ve veri madenciliği yöntemiyle bulunmuştur. Doğruluk oranı %99.2611'dir.

Tablo 4.1.14.1. Kanama riski tanısına ilişkin veriler ve doğruluk oranı tablosu

Kanama Riski	
İlişkili Veriler	Doğru Sınıflandırılmış Örnek Toplam Örnek Sayısı Sayısı ve Oranı
Üre	403 406
Cl	%99.2611
Albumin	
Alt	
Ca	
Hastanın Hastanede Yattığı Gün	
Ameliyat Biçimlerinden; Pelvik Lenf Nodu Diseksiyonu	
Ameliyat Biçimlerinden; Total Abdominal Histerektomi + Bilateral Salpingooferektomi	

4.1.15. Karaciğer fonksiyonunda bozulma riski tanısına ilişkin makine öğrenmesi bulguları

Bu bölümde Karaciğer Fonksiyonunda Bozulma Riski tanısına ilişkin veriler Ast, Alt, total bilirubin, hastalık şikayeti; ağrı, ameliyat biçimlerinden; Pelvik Lenf Nodu Diseksiyonu ile ilişkili olduğu makine öğrenmesi ve veri madenciliği yöntemiyle bulunmuştur. Doğruluk oranı %97.5369'dur.

Tablo 4.1.15.1. Karaciğer fonksiyonunda bozulma riski tanısına ilişkin veriler ve doğruluk oranı tablosu

Karaciğer Fonksiyonunda Bozulma Riski

İlişkili Veriler	Doğru Sınıflandırılmış Örnek Sayısı ve Oranı	Toplam Örnek Sayısı
Ast	369	406
Alt	%97.5369	
Total Bilirubin		
Hastalık Şikayeti; Ağrı		
Ameliyat Biçimlerinden; Pelvik Lenf Nodu Diseksiyonu		

4.1.16. Kardiyovasküler fonksiyonda bozulma riski tanısına ilişkin makine öğrenmesi bulguları

Bu bölümde Kardiyovasküler Fonksiyonda Bozulma Riski tanısına ilişkin veriler yaş, K, Albümin, Ast, Dm, Ht, kalp hastalığı bulunması, reflü, Ameliyat Biçimlerinden; Bridektomi, Ameliyat Biçimlerinden; Kolon Onarımı ile ilişkili olduğu makine öğrenmesi ve veri madenciliği yöntemiyle bulunmuştur. Doğruluk oranı %98.5222'dir.

Tablo 4.1.16.1. Kardiyovasküler fonksiyonda bozulma riski tanısına ilişkin veriler ve doğruluk oranı tablosu

Kardiyovasküler Fonksiyonda Bozulma Riski			
İlişkili Veriler	Doğru Sınıflandırılmış Örnek Sayısı ve Oranı	Toplam Örnek Sayısı	
Yaş	400	406	
K	%98.5222		
Albümin			
Ast			
Dm			
Ht			
Kalp Hastalığı Bulunması			
Obez			
Reflü			
Stres İnkontinansı			
Ameliyat Biçimlerinden; Bridektomi			
Ameliyat Biçimlerinden; Kolon Onarımı			

4.1.17. Aspirasyon riski tanısına ilişkin makine öğrenmesi bulguları

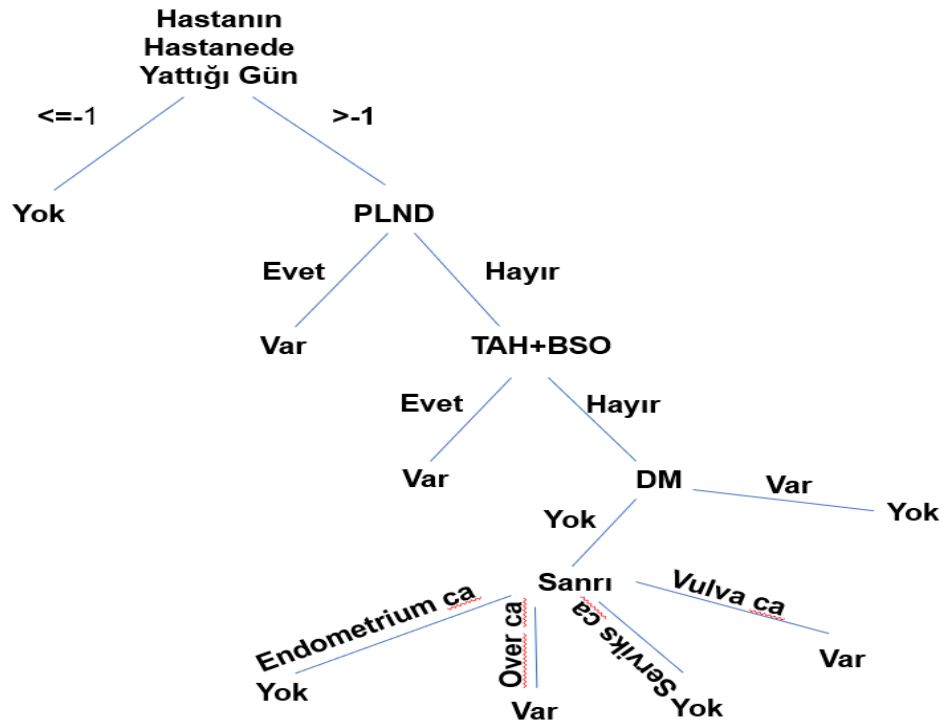
Bu bölümde Aspirasyon Riski tanısına ilişkin veriler, hastanın hastanede yattığı gün, koah, Parkinson, kan takılma durumu ile ilişkili olduğu makine öğrenmesi ve veri madenciliği yöntemiyle bulunmuştur. Doğruluk oranı %98.0296'dır.

Tablo 4.1.17.1. Aspirasyon riski tanısına ilişkin veriler ve doğruluk oranı tablosu

Aspirasyon Riski				
İlişkili Veriler			Doğru Sınıflandırılmış Örnek	Toplam Örnek Sayısı
			Sayısı ve Oranı	
Hastanın	Hastanede	Yattığı	398	406
Gün				
Koah			%98.0296	
Parkinson				
Kan Takılma Durumu				

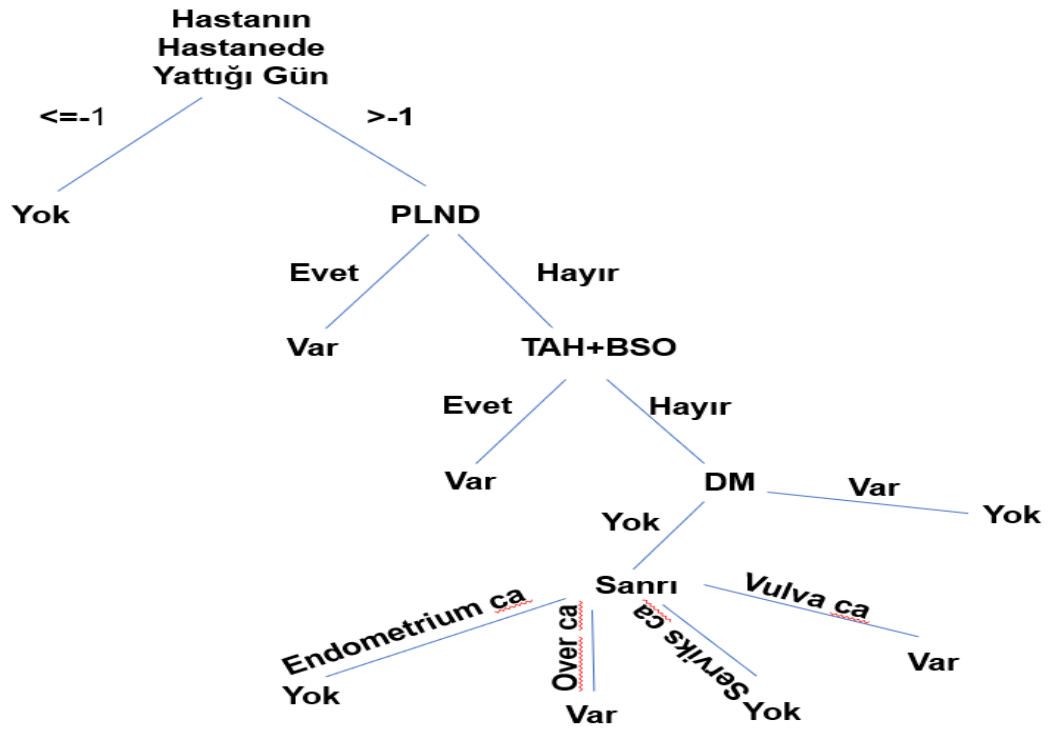
4.2. Veri Madenciliği ve Karar Ağaçları Bulguları

- Banyo Yapmada Özbakım Yetersizliği tanısına ilişkin veri madenciliği ve karar ağacı modeli
- Beslenmede Özbakım Yetersizliği tanısına ilişkin veri madenciliği ve karar ağacı modeli
- Tuvalet İhtiyacını Karşılama Özbakım Yetersizliği tanısına ilişkin veri madenciliği ve karar ağacı modeli
- Giyinmede Özbakım Yetersizliği tanısına ilişkin veri madenciliği ve karar ağacı modeli
- Konstipasyon tanısına ilişkin veri madenciliği ve karar ağacı modeli
- Beden İmajında Bozulma tanısına ilişkin veri madenciliği ve karar ağacı modeli
- Sözel İletişimde Bozulma tanısına ilişkin veri madenciliği ve karar ağacı modeli
- Stres İnkontinansı tanısına tanısına ilişkin veri madenciliği ve karar ağacı modeli
- Cerrahi İyileşmede Gecikme Riski tanısına ilişkin veri madenciliği ve karar ağacı modeli
- Doku Bütünlüğünde Bozulma Riski tanısına ilişkin veri madenciliği ve karar ağacı modeli
- Düşme Riski tanısına ilişkin veri madenciliği ve karar ağacı modeli
- Gastrointestinal Mobilitede Bozulma Riski tanısına ilişkin veri madenciliği ve karar ağacı modeli
- Kan Şekeri Düzeyinde Dengesizlik Riski tanısına ilişkin veri madenciliği ve karar ağacı modeli
- Kanama Riski tanısına ilişkin veri madenciliği ve karar ağacı modeli
- Karaciğer Fonksiyonunda Bozulma Riski tanısına ilişkin veri madenciliği ve karar ağacı modeli
- Kardiyovasküler Fonksiyonda Bozulma Riski tanısına ilişkin veri madenciliği ve karar ağacı modeli
- Aspirasyon Riski tanısına ilişkin veri madenciliği ve karar ağacı modeli



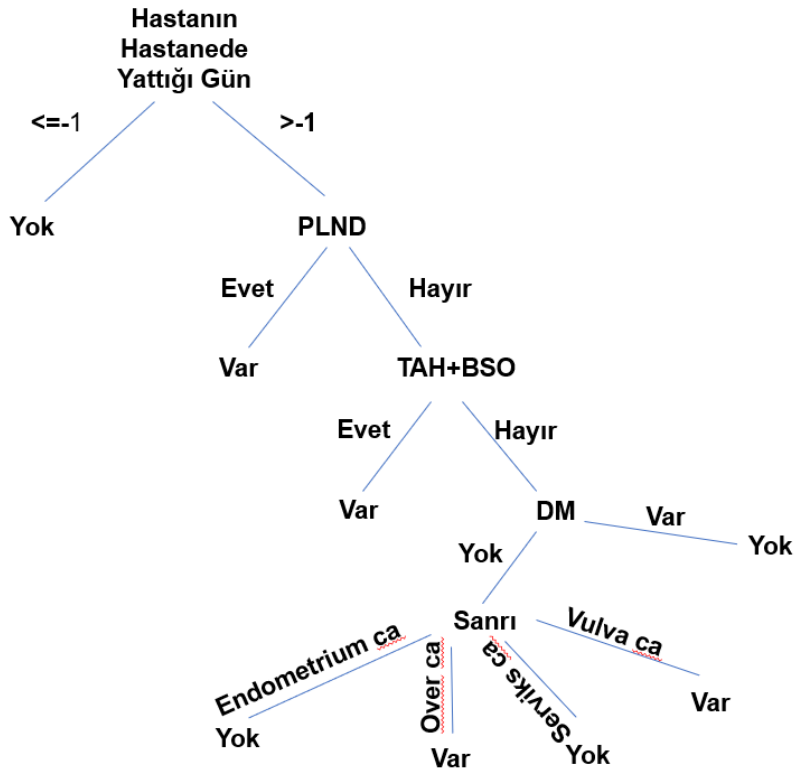
Şekil 4.1 Banyo yapmada özbakım yetersizliği tanısına ilişkin karar ağacı

Banyo Yapmada Özbakım Yetersizliği tanısına ilişkin karar ağacına göre, hastanın hastanede yattığı gün postoperatif dönemde 1'den küçükse tanı yok. Hastanın hastanede yattığı gün postoperatif dönemde 1'den büyükse pelvik lenf nodu diseksiyonu ameliyatı olmuşsa tanı var, olmamışsa Total Abdominal Histerektomi + Bilateral Salpingooferektomi ameliyatı olmuşsa tanı var, bu ameliyatı da olmamışsa diyabet hastasıysa tanı yok, diyabet hastası değilse sanrı şikayeti olmayıp over ca veya vulva caysa tanı vardır.



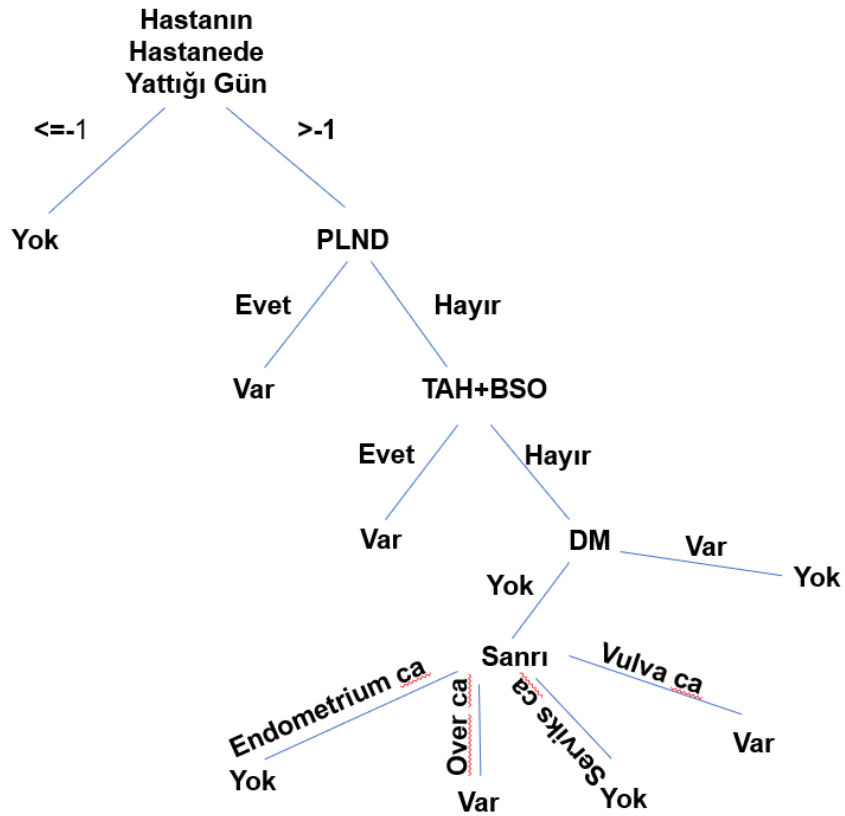
Şekil 4.2 Beslenmede özbakım yetersizliği tanısına ilişkin karar ağacı

Beslenmede Özbakım Yetersizliği tanısına ilişkin karar ağacına göre, hastanın hastanede yattığı gün postoperatif dönemde 1'den küçükse tanı yok. Hastanın hastanede yattığı gün postoperatif dönemde 1'den büyükse pelvik lenf nodu diseksiyonu ameliyatı olmuşsa tanı var, olmamışsa Total Abdominal Histerektomi + Bilateral Salpingooferektomi ameliyatı olmuşsa tanı var, bu ameliyatı da olmamışsa diyabet hastasıysa tanı yok, diyabet hastası değilse sanrı şikayeti olmayıp over ca veya vulva ca tanısı varsa vardır.



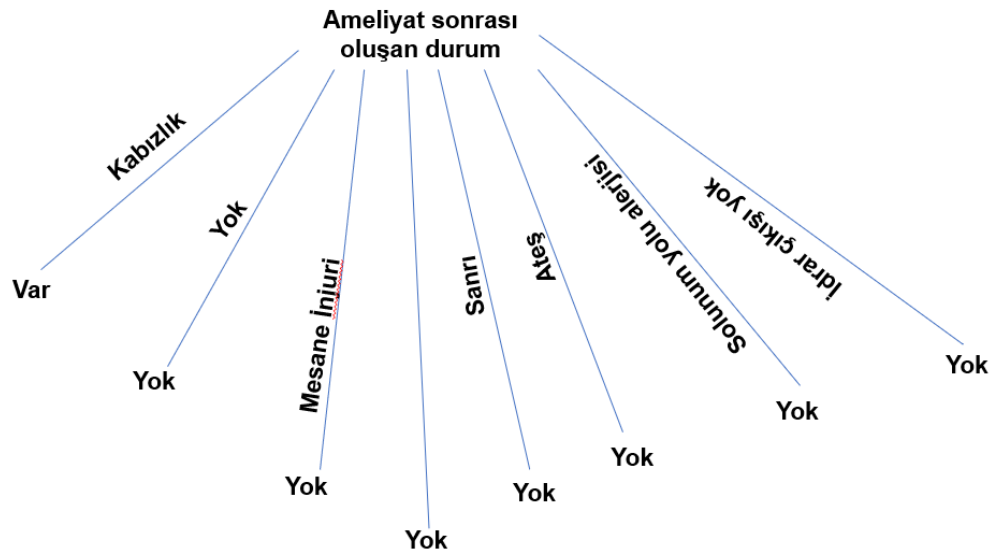
Şekil 4.3 Tuvalet ihtiyacını karşılamada özbakım yetersizliği tanısına ilişkin karar ağacı

Tuvalet İhtiyacını Karşılamada Özbakım Yetersizliği tanısına ilişkin karar ağacına göre, hastanın hastanede yattığı gün postoperatif dönemde 1'den küçükse tanı yok. Hastanın hastanede yattığı gün postoperatif dönemde 1'den büyükse pelvik lenf nodu diseksiyonu ameliyatı olmuşsa tanı var, olmamışsa Total Abdominal Histerektomi + Bilateral Salpingooferektomi ameliyatı olmuşsa tanı var, bu ameliyatı da olmamışsa diyabet hastasıysa tanı yok, diyabet hastası değilse sanrı şikayeti olmayıp over ca veya vulva caysa tanı vardır.



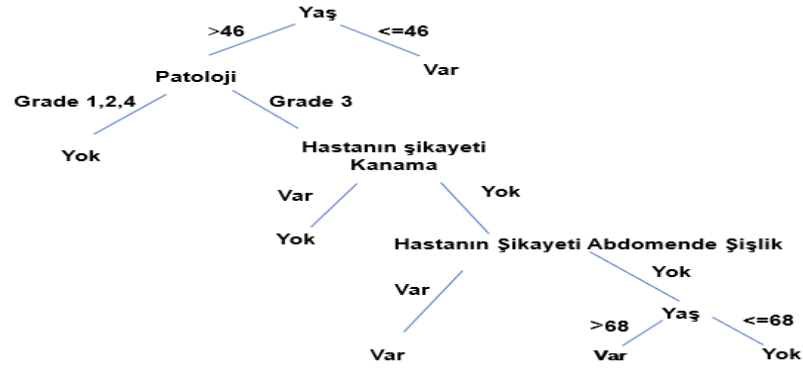
Şekil 4.4 Giyinmede özbakım yetersizliği tanısına ilişkin karar ağacı

Giyinmede özbakım yetersizliği tanısına ilişkin karar ağacına göre, hastanın hastanede yattığı gün postoperatif dönemde 1'den küçükse tanı yok. Hastanın hastanede yattığı gün postoperatif dönemde 1'den büyükse pelvik lenf nodu diseksiyonu ameliyatı olmuşsa tanı var, olmamışsa Total Abdominal Histerektomi + Bilateral Salpingooferektomi ameliyatı olmuşsa tanı var, bu ameliyatı da olmamışsa diyabet hastasıysa tanı yok, diyabet hastası değilse sanrı şikayeti olmayıp over ca veya vulva caysa tanı vardır.



Şekil 4.5 Konstipasyon tanısına ilişkin karar ağacı

Konstipasyon tanısına ilişkin karar ağacına göre, Ameliyat sonrası oluşan durumlardan; yok, Mesane injurisi, sanrı, ateş solunum yolu alerjisi, idrar çıkışı yoksa tanı yok, kabızlık varsa tanı vardır.




Şekil 4.6 Beden imajında bozulma tanısına ilişkin karar ağacı

Beden imajında bozulma tanısına ilişkin karar ağacına göre; Hastanın yaşı 46 veya 46'dan küçükse tanı var. Eğer hastanın yaşı 46'dan büyükse, patoloji sonucu Grade 1,2,4 ise tanı yok. Eğer patoloji sonucu Grade 3 ise, hastanın kanama şikayeti varsa tanı yok. Hastanın kanam şikayeti yok ancak abdomende şişlik şikayeti varsa tanı var. Hastanın Abdomende şişlik şikayeti yoksa yaşı 68'den büyükse tanı var. Hastanın abdomende şişlik şikayeti yoksa yaşı 68'den küçük veya eşitse tanı yok.



Şekil 4.7 Sözel iletişimde bozulma tanısına ilişkin karar ağacı

Sözel İletişimde Bozulma tanısına ilişkin karar ağacına göre, işitme kaybı varsa tanı vardır.



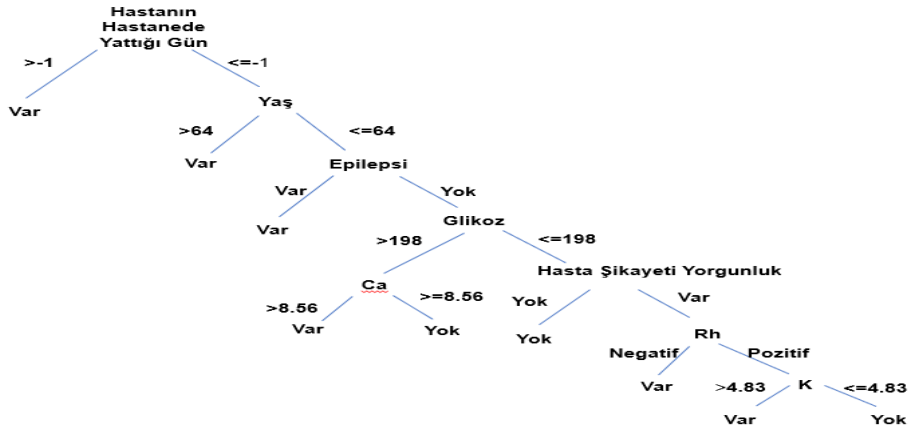
Şekil 4.8 Stres inkontinansı tanısına ilişkin karar ağacı

Stres İnkontinansı tanısına ilişkin karar ağacına göre, stres inkontinansı varsa tanı vardır.



Şekil 4.9 Doku bütünlüğünde bozulma riski tanısına ilişkin karar ağacı

Doku bütünlüğünde bozulma riskine ilişkin karar ağacına göre; hastanın hastanede yattığı gün preoperatif günü 1'e eşit veya küçükse tanı yok. Preoperatif günü 1'den büyükse hasta Pelvik Lenf Nodu Diseksiyonu ameliyatı olmadıysa, Total Abdominal Histerektomi + Bilateral Salpingooferektomi ameliyatı olup Potasyum değeri 3.09'den büyükse tanı var. Total Abdominal Histerektomi + Bilateral Salpingooferektomi ameliyatı olmamış, Salpenjektomi ameliyatı olmuşsa tanı var olmamışsa tanı yok. Pelvik Lenf Nodu Diseksiyonu ameliyatı ve Omentektomi ameliyatı olmuşsa tanı var. Omentektomi ameliyatı olmamışsa yaşı 47'den büyük veya 43'e eşit veya küçükse tanı var. Hastanın yaşı 43'den büyük ve hipertansiyon hastasıysa ve hastaneye yatış tarihi 2016'dan büyükse tanı var, 2016'a eşit veya küçükse tanı yok.




Şekil 4.10 Düşme riski tanısına ilişkin karar ağacı

Düşme riski tanısının karar ağacına göre; hastanın hastanede yattığı gün preoperatif günü 1'den büyükse tanı var. Preoperatif günü 1 veya 1'den küçükse yaşı 64'den büyükse tanı var. Yaşı 64 veya küçükse Epilepsi hastasıysa tanı var. Epilepsi hastası değilse glikoz değeri 198'in üzerinde ve kalsiyum değeri 8.56'dan büyükse tanı var. Kalsiyum değeri 8.56 veya küçükse tanı yok. Hastanın glikoz değeri 198 veya küçükse, hastanın şikayeti yorgunluk değilse tanı yok. Hastanın şikayeti yorgunluksa Rh değeri negatifse tanı var. Rh değeri pozitifse, Potasyum değeri 4.83'den büyükse tanı var, 4.83 veya küçükse tanı yok.



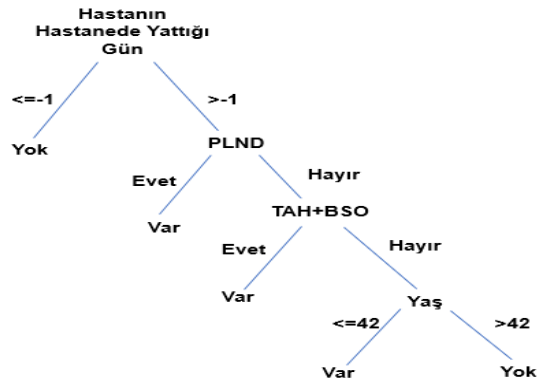
Şekil 4.11 Gastrointestinal mobilitede bozulma riski tanısına ilişkin karar ağacı

Gastrointestinal mobilitede bozulma tanısına ilişkin karar ağacına göre; hastanın hastanede yattığı gün preoperatif dönemde 1'e eşit veya küçükse tanı yok. Preoperatif günü 1'den büyükse ameliyat sonrası oluşan durumlardan mesane injuri, yüksek şeker seyri, sanrı, ateş, solunum yolu alerjisi, idrar çıkışı yoksa tanı var. Ameliyat sonrası oluşan durumlardan konstipasyon yoksa, Pelvik lenf nodu diseksiyonu ameliyatı olmuşsa tanı var, olmamışsa Total Abdominal Histerektomi + Bilateral Salpingooferektomi ameliyatı olmuşsa tanı var, olmamışsa yaşı 42'den büyükse tanı yok, 42 veya 42'den küçükse tanı var.




Şekil 4.12 Kan şekeri düzeyinde dengesizlik riski tanısına ilişkin karar ağacı

Kan şekeri düzeyinde dengesizlik tanısına ilişkin karar ağacına göre; Hasta diyabetse tanı var. Hasta diyabet değilse Glukoz değeri 199'un üzerindeyse tanı var, 79 veya 79'dan küçükse veya 57 veya 57'den küçükse tanı var.



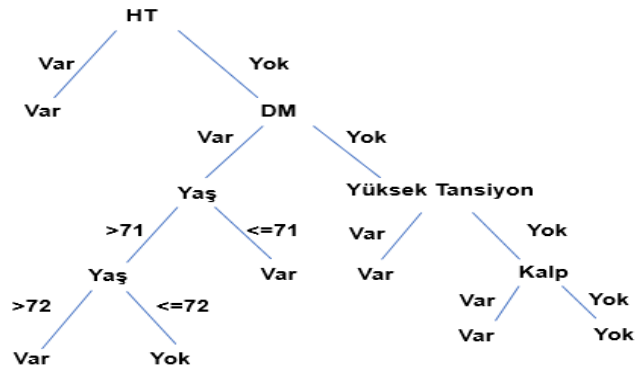
Şekil 4.13 Kanama riski tanısına ilişkin karar ağacı

Kanama riski tanısına ilişkin karar ağacına göre; hastanın hastanede yattığı gün preoperatif dönemde 1 veya 1'den küçükse tanı yok. Preoperatif günü 1'den büyükse Pelvik lenf nodu diseksiyonu ameliyatı olmuşsa tanı var, olmamışsa Total Abdominal Histerektomi + Bilateral Salpingooferektomi ameliyatı olmuşsa tanı var, olmamışsa yaşı 42'den büyükse tanı yok, 42 veya 42'den küçükse tanı var.



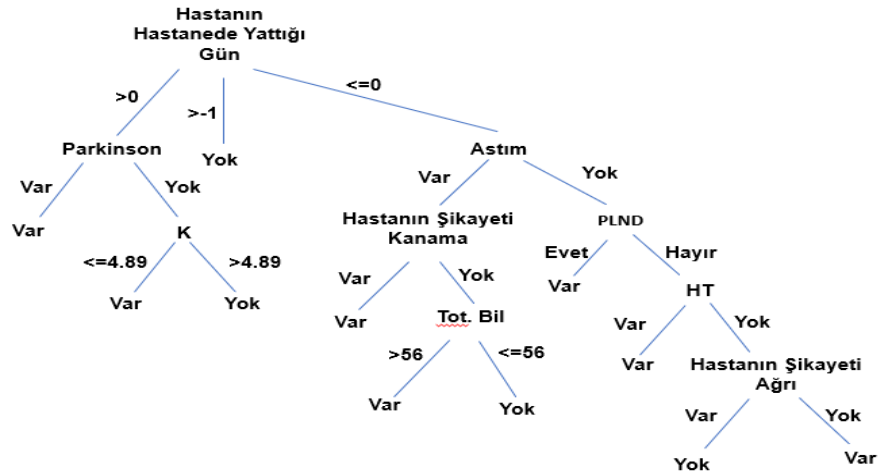
Şekil 4.14 Karaciğer fonksiyonunda bozulma riski tanısına ilişkin karar ağacı

Karaciğer fonksiyonunda bozulma riski tanısına ilişkin karar ağacına göre; AST değeri 35'den büyükse tanı var, 35 veya 35'den küçükse ALT değeri 43den büyükse tanı var, 43 veya 43den küçükse hastanın şikayeti yorgunluksa tanı var, değilse tanı yok.



Şekil 4.15 Kardiyovasküler fonksiyonda bozulma riski tanısına ilişkin karar ağacı

Kardiyovasküler fonksiyonda bozulma riskine ilişkin karar ağacına göre; hasta hipertansiyon hastasıysa tanı var, değilse hasta diyabetse yaşı 71 veya 72'den büyükse tanı var, 72'den küçükse tanı yok. Diyabet hastası değilse yüksek tansiyon hastasıysa tanı var, değilse kalp hastasıysa tanı var değilse tanı yok.



Şekil 4.16 Aspirasyon riski tanısına ilişkin karar ağacı

Aspirasyon riski tanısına ilişkin karar ağacına göre; hastanın hastanede yattığı gün postoperatif dönemdeyse ve Parkinson hastasıysa tanı var, Parkinson hastası değilse potasyum değeri 4.89 veya 4.89'dan küçükse tanı var, 4.89'dan büyükse tanı yok. Hastanın hastanede yattığı gün preoperatif dönemdeyse tanı yok. Hastanın hastanede yattığı gün postoperatif dönemdeyse astım hastasıysa, şikayeti kanamaysa tanı var, kanama değilse total bilirübin değeri, 56'dan büyükse tanı var, 56 veya 56'dan küçükse tanı yok. Astım hastası değilse pelvik lenf nodu diseksiyonu ameliyatı olmuşsa tanı var, olmamışsa hastanın hipertansiyonu varsa tanı var, yoksa hastanın şikayeti ağrıysa tanı yok, değilse tanı var.

5. TARTIŞMA

Bu araştırma hemşireler için en önemli yol gösterici olan NANDA bakım planları içerisinde yer alan Jinekolojik hastalarda konulan hemşirelik tanılarını makine öğrenmesi veri madenciliği yöntemiyle geliştirilmesi amacıyla planlanmıştır.

NANDA hemşirelik tanıları uluslararası geçerliliğe sahiptir. Dünya çapında hemşireler tarafından öğretim, araştırma veya hasta bakımı için çeşitli standartlaştırılmış terminolojiler kullanılmaktadır. Bu sistemler, hemşirelik kayıtlarının kalitesini artırabilir, bakım sürekliliğini, yazılı iletişimde tutarlılığı sağlayabilir ve hem hastalar hem de bakım sağlayıcıları için güvenliği artırabilmektedir. Böylece uluslararası hemşirelik bakımının standart olması sağlanabilmektedir (Robelo-Silva vd. 2016). Bu standartları sağlayabilmek için günümüz teknolojinde birçok olanak bulunmaktadır. Bunlardan birisi yapay zekadır. Yapay zeka, insan davranışlarını simüle eden makine ve ekipmanların keşfi, incelenmesi ve tasarımı ile ilgilenir. Bu makineler ve ekipmanlar, insan veya insana yakın zeka gösterir ve insanlar gibi düşünebilir, çalıştırabilir ve zeka işlevlerini kullanabilirler (Soda vd 2011). Yapay zeka teknolojisi kullanılarak hemşirelik tanılarının öğretildiği az sayıda çalışma bulunmaktadır. Ancak yapay zeka teknolojisine benzer sistemlerin geliştirildiği birkaç çalışma bulunmaktadır. Bunlardan birisi Endonezya'da bulunan bir hastanede yapılmıştır. Çalışmanın yapılma amacı, hemşirelik tanılarının yüksek doğruluğa sahip olduğunu belirlemek içindir. Çalışmanın verileri pediyatrik hastalık tanısı alıp tedavi gören kişilerden oluşmaktadır. Bronkopnömoni, bronşit, tifo ateşi, febris, gastroenterit, üst solunum yolu enfeksiyonu, ateşli nöbetler veya kızamık tıbbi tanısı olan pediyatrik hastalar yer almaktadır. Çalışma bir yapay zeka algoritması ile gerçekleşmemiştir. Web tabanlı ileri zincirleme çıkarım yöntemi kullanılarak çalışma yapılmıştır. Oluşturulan uzman sistem, hastanın yaşadığı semptomlara veya risk faktörlerine göre pediyatrik hastalar için hasta adı, yaşı, tıbbi tanı türü, yaşanan semptomlar ve çıkarım sonuçlarını içeren bir giriş menüsü içerir. Sistem hem gerçek hem

de risk tanılarında 235 belirti ve semptomla 58 tür hemşirelik tanısının yanı sıra bronkopnömoni, bronşit, tifo, sebris, gastroenterit, Üst solunum yolu enfeksiyonu, ateşli nöbetler ve kızamık dahil olmak üzere pediatrik hastalardaki sekiz tıbbi tanı türünden risk faktörlerini belirlemektedir. Uzman hemşireler tarafından elde edilmiş hemşirelik tanıları ile mevcut hemşirelik tanıları %100 benzerlik göstermektedir. Hemşirelerin evrak yükünü azaltarak ve hemşirelik tanılarının doğruluğunu gösteren bu veri tabanını ileri yapay zeka çalışmalarına ışık tutmaktadır (Hidayet ve Uliyalı 2018). Başka bir çalışmada NANDA hemşirelik tanılarında üriner eliminasyonla ilişkili uzman bir sistem geliştirilmiştir. Bu çalışmada yapay zeka çalışması değildir. Ancak yine hemşirelerin iş yükünü azaltmak ve konulan hemşirelik tanılarının doğruluğunu ortaya koymak için yapılmıştır. Uzman hemşireler tarafından üriner eliminasyon için hemşirelik tanı kriterleri oluşturulmuştur. Bu kriterler baz alınarak geliştirilen sistem 197 hasta üzerinde test edilmiştir. Çalışmanın sonucunda %98 oranında duyarlı olduğu bulunmuştur (Higa ve Lopes 2008). Bizim çalışmamızda veriler hastane otomasyon sistemine girilmiş olan veriler makine öğrenmesiyle formüle edilmiş, veri madenciliği ile en başarılı algoritma seçilmiştir. Otomasyon sisteminden elde ettiğimiz verilerde konulmuş hemşirelik tanısı olmadığı için araştırmacı tarafından algoritmalar oluşturulmuştur. Bu sebeple daha önce konulmuş hemşirelik tanıları ile kıyaslanma yapılmamıştır.

Literatürde bizim çalışmamıza benzer tek bir çalışma bulunmaktadır. Bu çalışma hastanede tedavi görüp taburcu olmuş olan 2011-2012 yılları arasında 105 kişinin verileri üzerinden yapılmıştır. Bu hastaların 216 tıbbi kaydı incelendikten sonra Gordon'un 11 işlevsel sağlık modeline göre, 4 yıllık klinik deneyime sahip kıdemli hemşireler, ana değerlendirici olarak hemşirelik tanılarını belirlemişlerdir. Belirledikleri tanımlar ile sistemde bulunan mevcut hemşirelik tanıları kıyaslanmıştır (Liao vd. 2015). Bizim çalışmamızda Gordon'un sağlık modeli kullanılmamıştır. Hastaneden elde ettiğimiz 38 tıbbi veri kaydı Gordon sağlık modelini karşılamamaktadır. Aynı çalışmada 105 hasta üzerinden alınan veriler SPSS yazılımına kodlama, yaş, cinsiyet, semptomlar (toplam 18 alan) ve hemşirelik tanıları (toplam 5 alan) dahil olmak üzere 26 alanla girilmiştir. Bu çalışmada, Veri Madenciliği için Sektörler Arası Standart İşleme dayalı bir tahmin modeli oluşturulmuştur. Çalışmanın yapıldığı yıl içerisinde hastanın yatışından elde edilen veriler kullanılmıştır. Kullanılan veriler ön işleme tabi tutulmuştur. Ön işleme, bu çalışma tarafından geliştirilen tahmin modelinin doğruluğunu etkileyebilecek parazit ve eksik verilerin etkilerini azaltmak için bilgilerin taranmasını, silinmesini ve düzenlenmesini içermektedir. Hemşirelik tanılarını etkileyebilecek faktörler, ilgili literatüre dayalı olarak araştırılmış ve ardından girdi değişkenleri olarak entegre edilmek üzere hasta dosyalarından birincil ayırt edici faktörler seçilmiştir. İki gruba ayrılan verilerin bir kısmı

eđitim grupları olarak kullanılmıř ve geri kalan grup ise geerliliđi test etmek iin test grubu olarak kullanılmıřtır. Tahmin modelleri oluřturulmuř ve eřitli deneme modellerinden en iyi model, model dođruluđu karřılařtırılarak seilmiřtir. Aynı alıřmada, veri madenciliđi ve istatistiksel analiz iin analiz araları olarak IBM SPSS, Clementine 12.0'daki karar ađacı, bir BPN ve MATLAB'deki ANFIS'i kullanılmıřtır. Eđitim ve test gruplarındaki 216 hemřirelik tanısından beř yaygın hemřirelik problemi ve bu problemlerle ilgili 18 faktör (belirti ve bulgular) genelleřtirilerek ve karar ađacı algoritması kullanılarak, ađaç diyagramı ve karar ađacından hata oranını elde edilmiřtir. Belirlenen 11 fonksiyonel sađlık örüntüsü arasında sađlık algısı, beslenme, aktivite ve uyku-dinlenme istatistiksel olarak anlamlı etkileyen faktörler olarak bulunmuřtur. Hemřirelik tanıları arasında en sık akut ađrı, rahatsızlık ve aktivite intoleransı görölmüřtür. MATLAB'daki ANFIS modeli, klinik tanıların dođruluđunu belirlemek iin kullanılmıřtır. ANFIS, yüzde 84,82'lik bir nihai dođruluk oranı ve yüzde 15,18'lik bir hata oranı vermiřtir. Tanılar iin 63 hemřireye üç ay eđitim verilmiřtir. Bu hemřirelerin üzerinde oluřturulan algoritma test edilmiřtir. Bilgi sistemi tarafından önerilen hemřirelik tanılarının, hemřireler tarafından konulanlarla örtüřen toplam örneklem iindeki dođruluk oranı yüzde 87 olarak bulunmuřtur. Hemřirelere yapılan anket sonuçlarına göre hemřirelik tanılarına iliřkin iř memnuniyetinin yüzde 41,1'den yüzde 75'e yükseldiđini ve karar verme iin harcanan zamanın artarak, 35,5 dakikadan 19,8 dakikaya düřtüđü saptanmıřtır (Liao vd. 2015). Bizim alıřmamız da veri madenciliđi yöntemi kullanılarak geliřtirilmiřtir. Halka aık ücretsiz ve aynı zamanda ierisinde birok veri tabanı, yapay zeka algoritmaları seilmesi sebebiyle WEKA programı kullanılmıřtır. Bu programda verilerimiz iřlenmeden önce temizleme, dönüřtürme adımlarından gemiřtir. Algoritma oluřturulmadan önce hemřirelik tanılarıyla iliřkili literatür taraması yapılmıř ve veriler ona göre seilip gruplandırılmıřtır. Dönüřtürölen veriler kullanılarak en uygun veri tabanı denenmiř ve seilmiřtir.

6. SONUÇ

Hemşireler için en önemli yol gösterici olan NANDA hemşirelik tanılarının içerisinde yer alan Jinekolojik hastalarında konulan hemşirelik tanılarının daha etkin hemşirelik tanılarının elde edilmesi amaçlayarak yapılan bu çalışmada aşağıdaki sonuçlar elde edilmiştir.

- Hemşireler için en önemli yol gösterici olan NANDA bakım planları içerisinde yer alan Jinekolojik hastalarda konulan hemşirelik tanılarını veri madenciliği, yapay sinir ağları ile geliştirdiğimiz algoritmada 17 hemşirelik tanısı elde ettik
- Bu hemşirelik tanılarının doğruluk oranları ortama olarak %98'dir.
- 17 hemşirelik tanısı; Banyo yapmada özbakım yetersizliği, beslenmede özbakım yetersizliği, tuvalet yapmada özbakım yetersizliği, giyinmede özbakım yetersizliği, konstipasyon, beden imajında bozulma, sözel iletişimde bozulma, stres inkontinansı, cerrahi iyileşmede gecikme riski, doku bütünlüğünde bozulma riski, düşme riski, gastrointestinal mobilitede bozulma riski, kan şekeri düzeyinde dengesizlik riski, kanama riski, karaciğer fonksiyonunda bozulma riski, kardiyovasküler fonksiyonda bozulma riski, aspirasyon riski tanıları makine öğrenimi ve veri madenciliği yöntemiyle geliştirilmiştir.
- Bu çalışma sonuçları, hemşirelerin makine öğrenimi ve veri madenciliği yöntemiyle hemşirelik tanısı koyabilmeleri için uygun bir yöntemdir.
- Özellikle hemşirelik tanıları içerisinde yer alan risk faktörleriyle ilişkili verilerin makine öğrenimi ve veri madenciliği yöntemi ile analiz edilmesi NANDA hemşirelik tanılarıyla ilişkili yeni veri faktörlerinin oluşturulmasına olanak sağlayacaktır.

Öneriler:

Bu sonuçlar, jinekolojik kanser hastalarında NANDA hemşirelik tanılarının makine öğrenmesi ve veri madenciliği yöntemi ile hemşirelik tanılarının konulabildiği belirlenmiştir. Bu doğrultuda araştırmadan elde edilen sonuçlara göre;

- Gelecekte yapılan çalışmalarda verilerin, hemşirelik tanıları için eğitim verilmiş hemşirelerden oluşturulan uzman bir ekip tarafından toplanması makine öğrenimi ve veri madenciliği yöntemi için daha sağlıklı hemşirelik tanılarının ortaya çıkmasına neden olacağı düşünülmektedir.
- Hastane otomasyon sistemine girilen tıbbi ve hemşirelik verilerinin doğru girilmesinin sağlanması bu tür yapılacak çalışmalara doğru bilgi akışının sağlanmasına neden olacaktır. Bu nedenle sağlık profesyonellerine doğru veri girişiyle ilgili eğitimlerin yapılması önerilmektedir.
- Makine öğrenimi ve veri madenciliği yöntemiyle yapılacak çalışmaların artması sonucu sağlık profesyonelleri sadece analiz edilen verilerle hastalarının tanı, tedavi ve bakımında aktif rol alabileceklerdir. Sağlık profesyonelleri teknolojik gelişmelerle ilgili yeni yöntemleri kullanmaları için teşvik edilmelidir.
- Hemşirelerin makine öğrenimi ve veri madenciliği yöntemiyle ilgili bilgi seviyelerin artmasıyla bu tür çalışmaların artacağı düşünülmektedir. Bu şekilde literatüre katkı sağlanması önerilmektedir.
- Hemşirelik tanılarıyla ilişkili yapay zeka çalışmalarının artması sonucunda hemşirelerin anamnez bilgilerini dokümanatik cihazlarla alarak, hastanın verebileceği cevapları önceden tahmin eden algoritmalarının olabileceği düşünülmektedir.
- Yapay zeka çalışmaları sonucunda elde edilen hemşirelik tanıları ile daha kapsamlı ve doğru hemşirelik tanılarının konulacağı düşünülmektedir.

KAYNAKLAR

Adams ID, Chan M, Clifford PC, Cooke WM, Dallos V, Dombel FTD, Edwards MH, Hancock DM, Hewett DJ, Mcintyre N, Somerville PG, Spiegelhalter DJ, Wellwood J, Wilson DH. Computer aided diagnosis of acute abdominal pain: a multicentre study. **British Medical Journal Volume** 1989; 293 (27): 1-3.

Akalın B, Veranyurt Ü. Sağlık Hizmetleri ve Yönetiminde Yapay Zeka. **Acta Infologica** 2021; 5: 1-10.

Akalın B, Veranyurt Ü. Sağlık 4.0 ve Sağlıkta Yapay Zekâ. **J Health Pro Res** 2022; 4(1): 57-64.

Akazawa M, Hashimoto K. Artificial Intelligence in Ovarian Cancer Diagnosis. **Anticancer Research** 2020; (40): 4795-4800.

Allred K, Gerardi N. Computer Simulation for Pain Management Education: A Pilot Study. **by the American Society for Pain Management Nursing** 2017; 278-287.

Alvarez AG, Sasso GTMD. Aplicação de objeto virtual de aprendizagem, para avaliação simulada de dor aguda, em estudantes de enfermagem. **Rev. Latino-Am. Enfermagem** 2011; 19(2): 1-9.

Asmirajanti Y, Hamid AYS, Hariyati TS. Nursing care activities based on Documentation. **BMC Nursing** 2019; 18(32): 1-5.

Altuntaş EY. Sağlık hizmetleri uygulamalarında dijital dönüşüm, **Eğitim Yayınevi**, Konya, 2019, s.1-125.

Aydemir E. 'Veri madencilik ve öğrenme' Weka ile yapay zeka, **Seçkin Yayıncılık**, Ankara, 2019, s.21-33.

Bacaksız FE, Yılmaz M, Ezizi K, Alan H. Sağlık Hizmetlerinde Robotları Yönetmek, **Journal of Health and Nursing Management** 2020; (3): 458-465.

Bagoni G, Ditto A, Martinelli F, Signorelli M, Chiappa V, Maggiore U.L.R, Taverna F, Lombardo C, Borghi C, Scaffa C, Lorusso D, Raspagliesi F. Artificial intelligence estimates the impact of human papillomavirus types in influencing the risk of cervical dysplasia recurrence: progress toward a more personalized Approach. **J Gynecol Oncol** 2019; 30(2): 1-6.

Bahado-Singh RO, Sonek J, Mckenna D, Cool D, Aydas B, Turkoglu O, Bjorndahl T, Mandal R, Wishart D, Friedman P, Graham SF, Yilmaz A. Artificial intelligence and amniotic fluid multiomics: prediction of perinatal outcome in asymptomatic women with short cervix. ***Ultrasound Obstet Gynecol*** 2019; 54: 110-118.

Bakken Henry S, Mead CN. Nursing Classification Systems: Necessary but not Sufficient for Representing “What Nurses Do” for Inclusion in Computer-based Patient Record Systems. ***J Am Med Informatics Assoc*** 1997; 4(3): 222–32.

Barrera A, Gee C, Wood A, Gibson O, Bayley D, Geddes J. Introducing artificial intelligence in acute psychiatric inpatient care: qualitative study of its use to conduct nursing observations, ***Based Ment Health*** 2020; (23): 34–38.

Barrett M, Boyne J, Brandts J, Brunner-La Rocca HP, Maesschalck, L, Wit K. Golubnitschaja O. Artificial intelligence supported patient self-care in chronic heart failure: A paradigm shift from reactive to predictive, preventive and personalised care. ***Epma Journal*** 2019; 10(4): 445-464.

Baykal A. Veri Madenciligi Uygulama Alanlari. ***Dicle Üniversitesi Ziya Gökalp Eğitim Fakültesi Dergisi*** 2006; 95-107.

Bilge U. Tıpta Yapay Zeka ve Uygulama Sistemleri. ***Türkiye Bilişim Derneği Kongresi*** 2007; 113-118.

Biröl L. Hemşirelik süreci, ***Etki Yayınları***, İstanbul, 2010, s. 35-45.

Cai Y, Clinto M, Xiao Z. Artificial Intelligence Assistive Technology in Hospital Professional Nursing Technology. ***Journal of Healthcare Engineering*** 2021; 1-7.

Carpenito LJ, Erdemir F. Hemşirelik Tanıları: El Kitabı, ***Nobel tıp Kitabevleri***, Adana, 2012, s.10.

Carroll W. Artificial Intelligence. Nurses and the Quadruple Aim. ***Online Journal of Nursing Informatics*** 2018; 1-3.

Che D, Hockenbury C, Marmelstein R, Rasheed K. Classification of genomic islands using decision trees and their ensemble algorithms. ***BMC Genomics*** 2010; 11(2): 2-9.

Chen C, Loh E, Kuo KN, Tam KW. The Times they Are a-Changin’ – Healthcare 4.0 Is Coming!. ***Journal of Medical Systems*** 2020; 44 (40): 1-4.

Chen M, Decary M. Artificial intelligence in healthcare: An essential guide for health leaders, ***Healthcare Management Forum*** 2020; (33): 10-18.

Choi RY, Coyner AS, Kalpathy-Cramer J, Chiang MF, Campbell P. Introduction to Machine Learning, Neural Networks, and Deep Learning. ***Transl Vis Sci Technol*** 2020; 9(2): 1-12.

Clancey WJ, Buchanan BG. Intelligent Computer-Aided Instruction For Medical Diagnosis. ***Silver Springs*** 1979; 175-183.

Clancy TR. Artificial Intelligence and Nursing: The Future Is Now. **JONA** 2020; 50(3): 125-127.

Clipper B, Batcheller J, Thomaz AL, Rozga A. Artificial intelligence and robotics: A nurse leader's primer. **Nurse Leader** 2018; 16(6): 379-384.

Craven FR, Hirnle JC, Jensen S. Fundamentals of nursing human health and function. **Third Edition, Philadelphia: LippincottCompany** 2013; 568-533.

Çoşkun F, Gülleroğlu HD. Yapay Zekanın Tarih İçindeki Gelişimi ve Eğitimde Kullanılması. **Ankara Üniversitesi Eğitim Bilimleri Fakültesi Dergisi** 2021; (54): 947-966.

Deo RC. Machine Learning in Medicine. **Circulation** 2015; 132(20): 1920–1930.

Deperlioğlu O, Köse U. An educational tool for artificial neural networks. **Computers and Electrical Engineering** 2011; 37(3): 392-402.

Dinç L. Bakım Kavramı ve Ahlaki boyutu. **Sağlık Bilimleri Fakültesi Hemşirelik Dergisi** 2010; 74-82.

Doğan A. Yapay zekâ, **Kariyer Yayıncılık**, İstanbul, 2002.

Dombal FT, Leaper DJ, Staniland JR, Mccann AP, Horrocks JC. Computer-Aided Diagnosis Of Acute Abdominal Pain **British Medical Journal** 1972; (2): 9-13.

Dong A, Gua J, Cea Y. Medical Information Mining-Based Visual Artificial Intelligence Emergency Nursing Management System. **Journal of Healthcare Engineering** 2021; 1-9.

Du Q, Liang D, Zhang D, Chen G, Li X. Evaluation of Functional Magnetic Resonance Imaging under Artificial Intelligence Algorithm on Plan-Do-Check-Action Home Nursing for Patients with Diabetic Nephropathy. **Contrast Media & Molecular Imaging** 2022; 1-8.

Eğrioglu E, Aladağ CH, Yolcu U, Uslu VR, Basaran MA. A new approach based on artificial neural networks for high order multivariate fuzzy time series. **Expert Systems with Applications** 2009; 36(7): 10589-10594.

Elmas Ç. Yapay sinir ağları, **Seçkin Yayıncılık**, Ankara, 2003.

Emel GG, Taşkın Ç. Veri Madenciliğinde Karar Ağaçları ve Bir Satış Analizi Uygulaması. **Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi** 2005; 6(2): 221-239.

Enilda N. Nursing Pain Assessment and Managemen: A 3D Interactive Simulation. **International Journal of Designs for Learning** 2014; 5(1): 43-56.

Erer MT, Akbaş M, Yıldırım G. Hemşirelik Sürecinin Evrimsel Gelişimi Hemşirelik Süreci. **Lokman Hekim Dergisi** 2017; 7(1): 1-5.

Ergin E, Karaarslan D, Şahan S, Yücel ŞÇ. Artificial intelligence and robot nurses: From nurse managers' perspective: A descriptive cross-sectional study. **J Nurs Manage** 2022; 1-10.

Ersoy Altınok N. Yapay Zeka ve Hemşirelik. **ISMSIT 2019** 2019; 211-215.

Fan Y, Meng Y, Yang S, Wang L, Zhi W, Lazare C, Cao C, Wu P. Screening of Cervical Cancer with Self-Collected Cervical Samples and Next-Generation Sequencing. **Hindawi Disease Markers** 2018; 1-4.

Ferizi U, Besser H, Hysi P, Jacobs J, Rajapakse C.S, Chen C, Saha PK, Honig S, Chang G. Artificial Intelligence Applied to Osteoporosis: A Performance Comparison of Machine Learning Algorithms in Predicting Fragility Fractures From MRI Data. **J Magn Reson Imaging** 2019; 49(4): 1029-1038.

Giudici P. Applied Data Mining: Statistical Methods for Business and Industry, **J Wiley & Sons Inc, Chichester, India**, 2003, s. 1-376.

Goyal A, Kuchana M, Ayyagari KPR. Machine learning predicts live-birth occurrence before in-vitro fertilization treatment, **Scientific Reports** 2019; 10: 1-12.

Guo Y, Wang J, Yan S, Sui S. Clinical Efficacy Evaluation of Psychological Nursing Intervention Combined with Drugs Treatment of Children with ADHD under Artificial Intelligence. **Journal of Healthcare Engineering** 2022; 10(20925): 1-10.

Hamet P, Tremblay J. Artificial intelligence in medicine. **Metabolism clinical and experimental** 2017; 36-40.

Hastie T, Tibshirani R, Friedman JH. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. **2nd ed. New York, NY: Springer** 2009; 1-179.

Herland M, Khoshgoftaar TM, Wald R. A review of data mining using big data in health informatics. **Journal of Big Data** 2014; 1(2): 1-35.

Hidayet AAA, Uliyah M. Analysis Of Nursing Diagnosis Using An Expert System In Paediatric Patients. **International Journal of Civil Engineering and Technology (IJCIET)** 2018; 9(8): 17-26.

Higa R, Lopes MHBM. Evaluation of an expert system on nursing diagnoses related to urinary elimination. **Pesquisa financiada pela Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP)** 2008; 61(5): 565-569.

Hong L, Cheng X, Zheng D. Application of Artificial Intelligence in Emergency Nursing of Patients with Chronic Obstructive Pulmonary Disease. **Contrast Media & Molecular Imaging** 2021; 1-6.

Hoşgör H, Güngördü H. Sağlıkta Yapay Zekanın Kullanım Alanları Üzerine Nitel Bir Araştırma. **Avrupa Bilim ve Teknoloji Dergisi** 2022; (35): 395-407.

Hu X, He X. Evaluation of the Postoperative Nursing Effect of Thoracic Surgery Assisted by Artificial Intelligence Robot. **Contrast Media & Molecular Imaging** 2021; 1-6.

Huang C, Xiang Z, Zhang Y, Tan DS, Yip CK, Liu Z, Li Y, Yu S, Diao L, Wong LY, Ling WL, Zeng Y, Tu W. Using Deep Learning in a Monocentric Study to Characterize Maternal Immune Environment for Predicting Pregnancy Outcomes in the Recurrent Reproductive Failure Patients. **Frontiers in Immunology** 2021; (12): 1-13.

James G, Witten D, Hastie T, Tibshirani R. An Introduction to Statistical Learning: With Applications in R. **New York: Springer** 2013; 1-426.

Jiang N, Xie H, Lin J, Wang Y, Yin Y. Diagnosis and Nursing Intervention of Gynecological Ovarian Endometriosis with Magnetic Resonance Imaging under Artificial Intelligence Algorithm, Computational. **Intelligence and Neuroscience** 2022; 1-10.

Keskenler MF, Keskenler EF. Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi. **Takvim-i Vekayi** 2017; 5(2): 8-18.

Kızılkaya Aydoğan E, Gencer C, Akbulut S. Veri Madenciliği Teknikleri ile Bir Kozmetik Markanın Ayrılan Müşteri analizi ve Müşteri Bölümlenmesi. **Journal of Engineering and Natural Sciences** 2008; 26(1): 43-57.

Kocaçal Güler E, Güneş Çelik G, Eşer İ. Tarihsel Süre İçinde Hemşirelik Süreci Ve Bakım Planların Gelişimi. **J Anatolia Nurs Heal Sci** 2021; 24(2): 284–90.

Kolanska K, Chabbert-Buffet N, Dara E, Antonie JM. Artificial Intelligence in Medicine: a matter of joy or concern?. **Journal of Gynecology Obstetrics and Human Reproduction** 2020; 1-18.

Kulikowski CA, Weiss SM, Representation of expert knowledge for consultation: the CASNET and EXPERT Projects". **Artificial intelligence in medicine** 1982; 1-35.

Koyuncugil A, Özgülbaş N. Veri Madenciliği: Tıp ve Sağlık Hizmetlerinde Kullanımı ve Uygulamaları. **Bilişim Teknolojileri Dergisi** 2009; 2(2): 21-32.

Letterie G. Three ways of knowing: the integration of clinical expertise, evidence-based medicine, and artificial intelligence in assisted reproductive Technologies. **Journal of Assisted Reproduction and Genetics** 2021; 1-9.

Li W, Liu Z, Song T, Zhang C, Xue J. Effect Evaluation of Electronic Health PDCA Nursing in Treatment of Childhood Asthma with Artificial Intelligence. **Journal of Healthcare Engineering** 2022; 1-12.

Liao P, Hsu P, Chu W, Chu W. Applying artificial intelligence technology to support decisionmaking in nursing: A case study in Taiwan, **Health Informatics Journal** 2015; 21(2): 137-148.

Lip GYH, Nieuwlaat R, Pisters R, Lane DA, Crijns HJGM. Refining clinical risk stratification for predicting stroke and thromboembolism in atrial fibrillation using a novel risk factor-based approach: the euro heart survey on atrial fibrillation. **Chest** 2010; 137(2): 263–272.

Liu Q, Yang L, Peng Q. Artificial Intelligence Technology-Based Medical Information Processing and Emergency First Aid Nursing Management. **Computational and Mathematical Methods in Medicine** 2022; 1-9.

Locsin RC, Ito H. Can humanoid nurse robots replace human nurses?. **Journal of Nursing** 2018; 5(1): 1-6.

MacFie J, ve McNaught C. The ethics of artificial nutrition. **Medicine** 2015; 43(2): 124-126.

Martarollo VG, Honorio KM, Silva ABF. Applications of Artificial Neural Networks in Chemical Problems. **INTEC** 2013; 204-223.

Mccarthy J. What is artificial intelligence. Computer Science Department Stanford University. **John McCarthy** 2004; 2-12.

McCormick KA, Lang N, Zielstorff R, Milholland DK, Saba V, Jacox A. Toward standard classification schemes for nursing language: Recommendations of the American nurses association steering committee on databases to support clinical nursing practice. **J Am Med Informatics Assoc** 1994;1(6): 421–7.

McGrow K. Artificial intelligence: Essentials for nursing. **Nursing** 2019; 49(9): 46–49.

Mintz Y, Brodie R. Introduction to artificial intelligence in medicine, **Minimally Invasive Therapy & Allied Technologies** 2019; 28(2): 73-81.

O'Mahony C, Jichi F, Pavlou M, Monserrat L, Anastasakis A, Rapezzi C, Biagini E, Gimeno JR, Limongelli G, McKenna WJ, Omar RZ, Elliott PM. A novel clinical risk prediction model for sudden cardiac death in hypertrophic cardiomyopathy (HCM risk-SCD). **Eur Heart J** 2014; 2010–2020.

Özkan HA, Bilgin Z. Hemşireliğin Felsefi Özü İyileştirme ve İyileştirici Bakım Yöntemleri. **HSP** 2016; 3(3): 191-200.

Öztemel E, Yayıncılık, **Papatya Yayıncılık**, İstanbul, 2003.

Paans W, Sermeus W, Nieweg RMB, Schans CP. Prevalence of accurate nursing documentation in patient records. **Journal of Advanced Nursing** 2010; 66(11): 2481-2489.

Peng G, Dong H, Liang T, Li L, Li J. Diagnosis of cervical precancerous lesions based on multimodal feature changes. ***Computers in Biology and Medicine*** 2021; 130: 1-8.

Rabelo-Silva ER, Cavalcanti ACD, Caldas MCRG, Lucena AF, Almeida MA, Linch GFC, Silva BM, Müller-Staub M. Advanced Nursing Process quality: Comparing the International Classification for Nursing Practice (ICNP) with the NANDA International (NANDA-I) and Nursing Interventions Classification (NIC). ***Journal of Clinical Nursing*** 2016; 379–387.

Ramesh AN, Kambhampati C, Monson JRT, Drew PJ. Artificial intelligence in medicine. ***Ann R Coll Surg Engl*** 2004; 86: 334-338.

Restivo K, The Drill on Data Mining, ***Computer Dealer News***, 1999, s.29-30.

Schwalbe N, Wahl B. Artificial intelligence and the future of global health. ***Lancet*** 2020; (395): 1579-1586.

Sechopoulos I, Teuwen J, Mann R. Artificial intelligence for breast cancer detection in mammography and digital breast tomosynthesis: State of the art. ***Seminars in Cancer Biology*** 2020; 1-39.

Shorey S, Ang E, Yap J, Ng E.D, Lau ST, Chui CK. A Virtual Counseling Application Using Artificial Intelligence for Communication Skills Training in Nursing Education: Development Study. ***J Med Internet Res*** 2019; (29): 21-32.

Soda P, Onofri L, Iannello G. A decision support system for Crithidia Luciliae image classification. ***Artificial Intelligence in Medicine*** 2011; 51: 67–74.

Stewart C, Ralyea C, Lockwood S. Ovarian Cancer: An Integrated Review. ***Seminars in Oncology Nursing***. ***Pages*** 2019; 35: 151-156.

Takahashi Y, Sone K, Noda K, Yoshida K, Toyohara Y, Kato K. Automated system for diagnosing endometrial cancer by adopting deep-learning technology in hysteroscopy. ***PLoS ONE*** 2021; 16(3): 1-13.

Taşcı ME, Şamlı R. Veri Madenciliği İle Kalp Hastalığı Teşhisi. ***European Journal of Science and Technology*** 2020; 88-95.

Tran WT, Sadeghi-Naini A, Lu F, Gandhi S, Meti N, Brackstone M, Rakovitch E, Curpen B. Computational Radiology in Breast Cancer Screening and Diagnosis Using Artificial Intelligence. ***Can Assoc Radiol*** 2021; 72(1): 98-108.

Turing AM. Mind a Quarterly Review of Psychology and Philosophy. ***Computer Science*** 1950; 443-460.

Yılmaz, A, Yapay Zeka, Aksan G, ***İnkilap Yayın Evi***, İstanbul, 2017, s. 181.

Yu H, Zhao Z, Duan X, Zhou J, Su D. Ultrasound Image under Artificial Intelligence Algorithm to Evaluate the Intervention Effect of Accelerated Rehabilitation Surgery Nursing on Laparoscopic Hysterectomy. **Computational Intelligence and Neuroscience** 2022; 1-11.

Zhang Y, Wang Z, Zhang J, Wang C, Wang Y, Chen H, Shan L, Huo J, Gu J, Ma X. Deep learning model for classifying endometrial lesions, **Journal of Translational Medicine** 2021; 19(10): 2-13.

Zhao Y. Effect Evaluation of Artificial Intelligence-Based Electronic Health PDCA Nursing Model in the Treatment of Mycoplasma Pneumonia in Children. **Journal of Healthcare Engineering** 2022; 1-10.

Zhao Z, Deng Y, Zhang Y, Zhang Y, Zhang X, Shao L. DeepFHR: intelligent prediction of fetal Acidemia using fetal heart rate signals based on convolutional neural network. **BMC Medical Informatics and Decision Making** 2019; 19(298): 1-15.

Zhou J, Zeng ZY, Li L. Progress of Artificial Intelligence in Gynecological Malignant Tumors. **Cancer Management and Research** 2021; 12: 12823-12840.

Wang Y, Wang X, Jin Y, We, X. X-Ray Film under Artificial Intelligence Algorithm in the Evaluation for Nursing Effect of Gamma Nail Internal Fixation in Elderly Patients with Intertrochanteric Fracture of Femur. **Computational and Mathematical Methods in Medicine** 2021; 1-11.

Wang F, Zhang P, Wang X, Hu J. Clinical Risk Prediction by Exploring High-Order Feature Correlations. **Watson Research Center** 2014; 1170-1179.

Warner HR, Toronto AF, Veasey LG, Stephenson R. A mathematical approach to medical diagnosis: application to congenital heart disease. **MD Comput** 1961; 9(1):43-50.

Wilkinson JM, Barcus L. Hemşirelik Tanıları El Kitabı, Kapucu S, Akyar İ, Korkmaz F. **Korza Yayıncılık Basım**, Ankara, 2018, s.23-1113.

Wu S, Li Y, Chen H, Ku ML, Yu Y, Nguyen P, Huang C. Using Artificial Intelligence for the Early Detection of Micro-Progression of Pressure Injuries in Hospitalized Patients: A Preliminary Nursing Perspective Evaluation. **Global Partnership for Digital Innovation** 2021; 1-2.

Qu W, Liu Q, Jiao X, Zhang T, Wang B, Li N, Dong T, Cui B. Development and Validation of a Personalized Survival Prediction Model for Uterine Adenosarcoma: A Population-Based Deep Learning Study. **Frontiers in Oncology** 2021; 1-10.

WEB_1. IBM Makine Öğrenimi <https://www.ibm.com/tr-tr/cloud/learn/machine-learning> (Son güncellenme tarihi 15.07.2020, alındığı tarih: 27.11.2022).

WEB_2. NANDA 2022 <https://nanda.org/> (Son güncellenme tarihi: 2023 Alındığı Tarih 01.01.2023)

WEB_3. The Technology Review Ten, MIT Technology Review 2001
<https://www.technologyreview.com/10-breakthrough-technologies/2001/> (Son
güncellenme tarihi 2021, alındığı tarih 27.11.2022).

World Health Organization. WHO guideline: Recommendations on digital interventions
for health system strengthening. **WHO**, United Kingdom, 2019, 1-150.

9.EKLER

EK1- Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu

Evrak Tarih ve Sayısı: 09.06.2021-E.60633



T.C.
PAMUKKALE ÜNİVERSİTESİ
Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu

Sayı : E-60116787-020-60633
Konu : Başvurumuz Hk.

Sayın Prof. Dr. Sevgi ÖZKAN

İlgi : 01/06/2021 tarihli dilekçeniz. 188.124.31.254
476

İlgi dilekçe ile başvurmuş olduğumuz "Jinekolojik Kanser Hastalarında NANDA Hemşirelik Tanılarının Makine Öğrenmesi Ve Veri Madenciliği Yöntemi İle Geliştirilmesi" konulu çalışmamız 08.06.2021 tarih ve 11 sayılı kurul toplantımızda görüşülmüş olup,

Yapılan görüşmelerden sonra; söz konusu çalışmanın yapılmasında ETİK AÇIDAN SAKINCA OLMADIGINA, altı ayda bir çalışma hakkında Kurulumuza bilgi verilmesine oy birliği ile karar verilmiştir.

Bilgilerinizi rica ederim.

Prof. Dr. Tahir TURAN
Başkan



EK-2. Veri Talep Onayı

Evrak Tarih ve Sayısı: 09.08.2021-E.82883



T.C.
PAMUKKALE ÜNİVERSİTESİ
Sağlık Araştırma ve Uygulama Merkezi



Sayı : E-65124556-600-81282
Konu : Merve VİCİR Araştırma

30.07.2021

SAGLIK BİLİMLERİ ENSTİTÜSÜNE

İlgi : 02.07.2021 tarihli ve 63288 sayılı yazı ^{2.08.2021 1.254}
476
3.12.2022

İlgide kayıtlı yazınıza istinaden hastanemiz Bilgi İşlem Biriminin Enstitünüz Hemşirelik Anabilim Dalı Doğum Kadın Hastalıkları Hemşireliği Yüksek Lisans programı öğrencisi Merve VİCİR'in "Jinekolojik Kanser Hastalarında NANDA Hemşirelik Tanılarının Makine Öğrenmesi ve Veri Yöntemi İle Geliştirilmesi" konulu tez çalışması için istenilen verileri şahsa elden teslim ettiği bilgisi alınmıştır.

Gereğini bilgilerinize rica ederim.

Prof. Dr. Selçuk YÜKSEL
Merkez Müdürü

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Belge Doğrulama Kodu : BSR6909PHF Pin Kodu :20262

Belge Takip Adresi : <https://www.turkiye.gov.tr/pau-dhy5>

Adres: Pamukkale Üniversitesi Hastaneleri

20070 Kamkh, DENİZLİ

Telefon: 0 (258) 296 60 00 Faks: 0 (258) 296 60 01

e-Posta: infohastane@pau.edu.tr Elektronik Ağ: infohastane@pau.edu.tr

Keşif Adresi: paurektorluk@hs01.kep.tr

Bilgi için: Meral KAPLAN

Unvanı: Büro Personeli



Tel No: 2966000-4879