

**T.C.
AKDENİZ ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ
Biyostatistik ve Tıbbi Bilişim Anabilim Dalı**

GERÇEK ZAMANLI MAMOGRAFİ YORUMU KARAR DESTEK SİSTEMİ

Selen BOZKURT

Doktora Tezi

Antalya, 2015

T.C.
AKDENİZ ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ
Biyoistatistik ve Tıbbi Bilişim Anabilim Dalı

GERÇEK ZAMANLI MAMOGRAFİ YORUMU KARAR DESTEK SİSTEMİ

Selen BOZKURT

Doktora Tezi

Tez Danışmanı

Yrd. Doç. Dr. Kemal Hakan GÜLKESEN

II. Tez Danışmanı

Yrd. Doç. Dr. Daniel RUBIN

“Kaynakça gösterilerek tezimden yararlanılabilir”

Antalya, 2015

Sağlık Bilimleri Enstitüsü Müdürlüğüne;

Bu çalışma jürimiz tarafından Biyoistatistik ve Tıbbi Bilişim Anabilim Dalı, Tıp Bilişimi Programında Doktora tezi olarak kabul edilmiştir./..../....

Tez Danışmanı : Yrd. Doç. Dr. Kemal Hakan GÜLKESEN
Akdeniz Üniversitesi
Tıp Fakültesi
Biyoistatistik ve Tıp Bilişimi Anabilim Dalı

Üye : Prof. Dr. Levent DÖNMEZ
Akdeniz Üniversitesi
Tıp Fakültesi
Halk Sağlığı Anabilim Dalı

Üye : Doç. Dr. Selçuk ÇÖMLEKÇİ
Süleyman Demirel Üniversitesi
Mühendislik Fakültesi
Telekomünikasyon Anabilim Dalı

Üye : Doç. Dr. Ahmet YARDIMCI
Akdeniz Üniversitesi
Tıp Fakültesi
Biyoistatistik ve Tıp Bilişimi Anabilim Dalı

Üye : Yrd. Doç. Dr. Neşe ZAYİM
Akdeniz Üniversitesi
Tıp Fakültesi
Biyoistatistik ve Tıp Bilişimi Anabilim Dalı

ONAY:

Bu tez, Enstitü Yönetim Kurulunca belirlenen yukarıdaki jüri üyeleri tarafından uygun görülmüş ve Enstitü Yönetim Kurulu'nun/..../2015 tarih ve/..... sayılı kararıyla kabul edilmiştir.

Prof. Dr. İsmail ÜSTÜNEL

Enstitü Müdürü

Sağlık Bilimleri Enstitü Kurulu Kararı Ve Akdeniz Üniversitesi Senato Kararı;

Sağlık Bilimleri Enstitüsü'nün 22.06.2000 tarih ve 02/09 sayılı Enstitü Kurul kararı ve 23.05.2003 tarih ve 04/44 sayılı Senato kararı gereğince "Sağlık Bilimleri Enstitülerinde lisansüstü eğitim gören doktora öğrencilerinin tez savunma sınavına girebilmeleri için, doktora bilim alanında en az bir yurtdışı yayın yapması gerektiği" ilkesi gereğince yapılan yayınların listesi aşağıdadır.

1. **Bozkurt S.** Lipson JA. Senol U. Rubin D. Automatic Abstraction of Imaging Observations with Their Characteristics from Mammography Reports. Journal of American Medical Informatics Association, 2014 [Epub ahead of print].
2. **Bozkurt S.**, Rubin D. Automated detection of ambiguity in BI-RADS assessment categories in mammography reports. Stud Health Technol Inform. 2014;197:35-9.
3. Yuce YK, Zayim N, Oguz B, **Bozkurt S.** Isleyen F. Gulkesen KH. Analysis of Social Networks among Physicians Employed at a Medical School. Studies in health technology and informatics 01/2014; 205:543-547.
4. **Bozkurt S.**, Gulkesen KH, Rubin D. Annotation for information extraction from mammography reports. Stud Health Technol Inform. 2013;190 p:183-5.
5. Bilge U, **Bozkurt S.**, Durmaz S, Application of data mining techniques for detecting asymptomatic carotid artery stenosis. Computers and Electrical Engineering, 2013; 39 (5) p: 1499-1505.
6. Bilge U, **Bozkurt S.**, Yolcular BO, Ozel D. Can Social Web Help o Detect Influenza Related Illnesses in Turkey? Stud Health Technol Inform. 2012;174, p:100-4.
7. **Bozkurt S.**, Kahn, CE. An Open-Standards Grammar for Outline-Style Radiology Report Templates. Journal of Digital Imaging 2012. 25(3) p: 359-364.
8. **Bozkurt S.**, Zayim N, Gulkesen K.H. Samur M.K. Karaagaoglu N. Saka O. Usability of a Web Based Personal Nutrition Management Tool. Informatics for Health and Social Care 2011;36(4) p:190-205.
9. Aktaş A, **Bozkurt S.**, Zayim N. Saka O. Yardimsever M. ICD-10 in a University Hospital from the Physicians' Perspective. Journal on Information Technology in Healthcare. 2008; 6(3) p: 221–22.

ÖZET

Radyoloji raporları genellikle yapılandırılmamış düz metinler halinde olup, karar destek için kullanılabilir bir çok veriyi içinde barındırmaktadırlar. Bunun yanı sıra raporlarda genellikle birden fazla lezyona ve bu lezyonların özelliklerine ait bilgiler bulunmakta ve bu durum her bir lezyona ait bilgi çıkarımı gibi ileri düzey bir çalışmayı gerektirmektedir. Bu çalışmanın amaçlarından ilki, doğal dil işleme yöntemleri ile yapılandırılmamış ya da yarı yapılandırılmış mamografi raporlarından karar destek sistemine girdi verisi olarak verilebilecek otomatik bilgi çıkarımı sağlayan bir sistem geliştirmektir. Bu amaçla, General Architecture for Text Engineering (GATE) NLP isimli platform kullanılarak, bir çok farklı bileşen içeren bir ardışık düzen geliştirilmiştir. Bu ardışık düzen sonucunda karar destek için gerekli olan veriler mamografi raporlarından çıkartılmaktadır. Geliştirilen sistem Stanford Üniversitesi görüntü bilişimi laboratuvarının kullanımına sunulmuş olan ve yapılandırılmış raporlama uygulamasını da destekleyen PenRad (PenRad, Buffalo, MN) isimli radyoloji veri tabanından seçilen 300 mamografi raporu üzerinde değerlendirilmiştir. Referans veri setinde 797 lezyon bulunurken sistem 815 lezyon saptamıştır (780 gerçek pozitif, 35 yanlış pozitif, 17 yanlış negatif). Geliştirilen bilgi çıkarımı sisteminin tüm lezyonların özellikleriyle birlikte saptanma doğruluğunu belirten kesinlik değeri 94,9 olup hassasiyet değeri 90,9'dur ve F ölçümü 92,8 olarak hesaplanmıştır.

Bir çok çalışmada mamografi değerlendirmelerinde gözlemler ve gözlemciler arası değişkenliğin önemli bir problem olduğu ve bu değişkenliği azaltmak için mamografide karar destek sistemlerinin kullanımının önemi vurgulanmıştır. Klinik değerlendirmeler sırasında ortaya çıkan bu ve benzeri problemlerin çözümünde karar destek sistemlerinin katkıları bilinse de, bulgulardaki değişkenlik gibi problemlerinin giderilmesine katkı sağlayan BI-RADS sınıflandırma sistemini içeren ve gerçek zamanlı sonuç veren bir karar destek sistemi bulunmamaktadır. Bu çalışmanın ikinci amacı, bilgi çıkarımı sisteminin çıkarttığı bilgileri karar destek sistemine girdi verisi olarak vererek, raporlama sırasında lezyonlara ait sonuç üretebilecek gerçek zamanlı karar destek sistemi (GZ-KDS) geliştirmek ve çıktılarını değerlendirmektir. Bilgi çıkarımı sistemi tarafından saptanan ve referans veri setinde bulunan verilerin karar destek sisteminde analizi ile elde edilen BI-RADS sınıflama kodları arasındaki uyumu ölçmek için hesaplanan ağırlıklandırılmış Kappa (k_w) değeri $\kappa=0.721$ olarak hesaplanmıştır ($p<0.01$). Bu değer iki veri seti arasında yüksek derecede uyum olduğunu göstermektedir. Bu çalışma birçok açıdan bir ilk çalışma olup, çalışmanın sonuçları, girdi verisinin otomatik olarak serbest metinlerden sağlandığı gerçek zamanlı karar destek sistemlerinin potansiyelini göstermiştir. Bu sistemlerin klinisyenlerin iş akışına kolayca entegre olabilmelerine ve yorumlardaki değişkenliğin azaltılmasına fayda sağlayacağı düşünülmektedir.

Anahtar Kelimeler: Breast Imaging Reporting and Data System (BI-RADS),
Bilgi Çıkarımı, Doğal Dil İşleme

ABSTRACT

Radiology reports are usually narrative, unstructured text, a format which hinders the ability to input report contents into decision support systems. In addition, reports often describe multiple lesions, and it is challenging to automatically extract each lesion and its relationships to characteristics, anatomic locations, and other information that describes it. One of the goals of this work is to develop natural language processing (NLP) methods to recognize each lesion in free-text mammography reports and to extract its corresponding relationships, producing a complete information frame for each lesion. NLP information extraction pipeline was built in the General Architecture for Text Engineering (GATE) NLP toolkit. Sequential processing modules are executed, producing an output information frame required for a mammography decision support system. Each lesion described in the report is identified by linking it with its anatomic location in the breast. In order to evaluate our system, we selected 300 mammography reports from a hospital report database, whose reports were created using a structured reporting application (PenRad, Buffalo, MN). The gold standard contained 797 lesions, and our system detected 815 lesions (780 true positives, 35 false positives, and 17 false negatives). The precision of detecting all the imaging observations with their modifiers was 94.9, recall was 90.9, and F measure was 92.8.

In mammography, Decision Support Systems (DSSs) are particularly important since there is variation in radiologist practice. The second goal of this study is to address the critical hurdle of enabling the deployment of DSS into the clinical workflow by developing a real-time mammography reporting decision support system (RT-MRDSS) for mammography that (1) extracts from narrative mammography reports a comprehensive set of inputs into a DSS for mammography, comprising radiologist-observed features and (2) provides real-time decision support about the diagnosis (as soon as the radiologist completes the report). We also present an initial evaluation of our RT-MRDSS system. In our case, the agreement in BI-RADS classification codes produced by our RT-MRDSS and by the gold standard was substantial ($\kappa_w=0.721$; $p<0.01$). Since our RT-MRDSS produces consistent results with consistent inputs, it is possible that it may reduce the variation in practice in mammography related to assessment of malignant lesions and biopsy decision. In addition, we believe our system will help radiologists to improve the completeness and consistency of their reports, with better clinical communication and practice improvement. With further testing, the system may ultimately help to improve mammography practice and improve the quality of patient care.

Key Words: Breast Imaging Reporting and Data System (BI-RADS), Information Extraction, Natural language processing

TEŞEKKÜR

Bu tezin hazırlanmasında bana rehberlik eden danışmanlarım Yrd. Doç. Dr. Kemal Hakan GÜLKESEN ve Yrd. Doç. Dr. Daniel Rubin'e,

Radyoloji alanında bilgileriyle bana destek veren Prof. Dr. Utku ŞENOL, Prof. Dr. Charles Kahn'a,

Çalışmalarım sırasında bana yol gösteren Anabilim Dalımız'daki değerli hocalarıma,

Bayes ağları konusunda bana destek veren proje arkadaşım Francisco Gimenez'e ve bilgi çıkarımı konusunda benimle deneyimlerini paylaşan arkadaşım Bethany Percha'ya,

Programlama konusunda desteğini aldığım proje arkadaşım Dr. Hakan Bulu'ya,

Lisansüstü eğitimim sürecinde verdikleri desteklerden dolayı Sağlık Bilimleri Enstitüsü'nün değerli çalışanlarına,

Tez çalışmalarımı yurtdışında yapmama destek olan TÜBİTAK Bilim İnsanı Destekleme Daire Başkanlığı'na (BİDEB),

Moral ve yardımlarını esirgemeyen mesai arkadaşlarıma,

Bana her zaman destek oldukları ve sağladıkları tüm imkanlar için aileme sonsuz teşekkürlerimi sunarım.

İÇİNDEKİLER

ÖZET	v
ABSTRACT	vi
TEŞEKKÜR	vii
İÇİNDEKİLER	viii
SİMGELER VE KISALTMALAR	x
ŞEKİLLER DİZİNİ	xi
ÇİZELGELER DİZİNİ	xii
GİRİŞ	1
GENEL BİLGİLER	2
2.1. Meme Kanseri ve Mamografi	2
2.1.1. Mamografi Yorumlarındaki Değişkenlik	2
2.1.2. BI-RADS (Breast Imaging Reporting and Data System)	3
2.2. Klinik Karar Destek Sistemleri	4
2.2.1. Klinik Karar Destek Sistemlerinin Yetersizlikleri	5
2.2.2. Gerçek Zamanlı Karar Destek Sistemleri (GZ-KDS)	6
2.2.3. Karar Destek Sistemlerine Veri Sağlamak Amacıyla Doğal Dil İşleme Yöntemlerinin Kullanılması	7
2.3. Doğal Dil İşleme	7
2.3.1. Metinden Bilgi Çıkarımı (Information Extraction)	8
2.3.2. Mamografi Raporlarından Bilgi Çıkarımı	9
GEREÇ VE YÖNTEM	11
3.1. Veri Seti	11
3.2. Karar Destek için Gerekli Olan Yapılandırılmış Verinin	12

Mamografi Raporlarından Çıkarılması	
3.2.1. DDİ ile Çıkarılacak Bilgiye ait Temel Kavramların Sunumu	13
3.2.2. Bilgi Çıkarımı Sürecinde Kullanılan Ardışık Düzen	14
3.3. Bilgi Çıkarımı Sisteminin Karar Destek Sistemi ile Entegrasyonu	21
3.4. Değerlendirme	23
3.4.1. Bilgi Çıkarımı Sisteminin Değerlendirilmesi	23
3.4.2. Bilgi Çıkarımı Sisteminin Genellenilebilirliğinin Değerlendirilmesi	24
3.4.3. Karar Destek Sisteminin Çıktılarının Değerlendirilmesi	24
BULGULAR	25
4.1. Bilgi Çıkarımı Sistemi Bulguları	25
4.2. Bilgi Çıkarımı Sistemi Genellenilebilirliği	26
4.3. Karar Destek Sistemi Sonuçlarının Karşılaştırılması	26
TARTIŞMA	27
SONUÇLAR	34
KAYNAKLAR	35
ÖZGEÇMİŞ	43
EKLER	44
EK-1: Microsoft Office Excel’de Çıktı Olarak Elde Edilen Örnek Veri Tablosu	
EK-2: JAPE ile Yazılmış Rapordaki Bölüm Başlıklarını Bulan Gramer Örneği	

SİMGELER VE KISALTMALAR

BI-RADS	:	Breast Imaging Reporting and Data System
ACR	:	American College of Radiology
DDİ	:	Doğal Dil İşleme
KDS	:	Karar Destek Sistemi
GZ-KDS	:	Gerçek Zamanlı Karar Destek Sistemi
İVT (NER)	:	İsmlendirilmiş Varlık Tanıma (Named Entity Recognition)
BÇ	:	Bilgi Çıkarımı
GATE	:	General Architecture for Text Engineering
NLP	:	Natural Language Processing
JAPE	:	Java Annotation Pattern

ŞEKİLLER DİZİNİ

Şekil	Sayfa
2.1. Mamografi tanıları için geliştirilen Bayes Ağ Modeli	5
2.2. İki ayrı lezyonun ve bu lezyonların marjin, değişkenlik ve şekil gibi farklı özelliklerinin tanımlandığı bir rapor örneği ile KDS'de kullanılmak üzere DDİ sisteminden elde edilmesi istenen çıktı	10
3.1. Bilgi çıkarımı sürecinde kullanılan ardışık düzen	12
3.2. BI-RADS ontolojisi. Varlık isimleri ve birbirleriyle olan ilişkileri	14
3.3. BI-RADS Onto-Gazetteer uygulamasının ile GATE NLP ortamında kullanımına ait ekran görüntüsü	15
3.4. Raporun bölümlere ayrılması işlemi sonucunun GATE NLP ortamındaki örnek ekran görüntüsü	16
3.5. Mamografi tanıları için geliştirilen Bayes Ağ Modeli (Modifiye edilmiş)	21
3.6. Bayes Ağ Modelinin Uygulamada Kullanımı	22
3.7. Karar Destek Sistemi Akış Diyagramı	22
3.8. Geliştirilen araçların iş akışı içerisinde gösterimi	23

ÇİZELGELER DİZİNİ

Çizelge	Sayfa
2.1. BIRADS tanı sınıflaması	3
3.1. Mamografi raporlarından çıkarılmak üzere tanımlanan varlık tipleri ve birbirleriyle olan ilişkileri	13
3.2. Özelliklerle varlıkların ilişkilendirilmesini sağlayan kural örnekleri	17
3.3. Lokasyon ve bulguların ilişkilendirilmesi için geliştirilen gramer	18
4.1. Lezyonlara ait bilginin çıkarımının değerlendirilmesi sonuçları	25
4.2. CT ve MR raporları için değerlendirme sonuçları	26
4.3. Karar Destek Sistemi Değerlendirmesi sonuçları	26

GİRİŞ

Geçmiş çalışmalarda kanser olasılığının mamografi bulgularının dikkatli incelemesiyle tahmin edilebileceği belirtilse de [1-4], bir çok çalışmada mamografi değerlendirmelerinde gözlemler ve gözlemciler arası değişkenliğin önemli bir problem olduğu vurgulanmıştır [5-9].

Mamografi bulgularında radyologlar arası yorum farklılıklarından kaynaklanan değişkenliği azaltmak ve hekimlere net sonuçlar verebilmek için önemli bir yaklaşım; mamografi raporlarında kullanılan terminolojinin standartlaştırılmasıdır. Bu amaçla geliştirilen Breast Imaging Reporting and Data System (BI-RADS) isimli sınıflandırma sistemi, mamografi raporlama sürecinde ortaya çıkan değişkenliği azaltmada önemli bir adım olsa da, karar verme sürecinde değişkenliği azaltmada ve radyologların elde ettikleri bulguları olası tanılarla nasıl ilişkilendirecekleri konusunda yetersiz kalmaktadır [10-13]. Uygulamadaki bu gibi yetersizlikler mamografi yorumlarındaki performansı yükseltmeye yardımcı olan karar destek sistemlerinin geliştirilmesi için fırsatlar sunmaktadır.

Klinik değerlendirmeler sırasında ortaya çıkan bu ve benzeri problemlerin çözümünde karar destek sistemlerinin katkıları bilinse de, bulgulardaki değişkenlik gibi problemlerin giderilmesine katkı sağlayan BI-RADS sınıflandırma sistemi tabanlı ve gerçek zamanlı sonuç veren bir karar destek sistemi bulunmamaktadır.

Bu çalışmanın amacı mamografi bulgularının kullanıldığı, BI-RADS sınıflandırma sistemi tabanlı ve radyolog gözlemleri dikte ederken gerçek zamanlı olarak çıktı veren bir karar destek sistemi geliştirilmesidir. Bu sistem, serbest metin halindeki (yapılandırılmamış ya da yarı yapılandırılmış) mamografi raporlarından yapılandırılmış verinin çıkartılması ve bu verinin karar destek amaçlı kullanılması olarak iki temel bileşenden oluşmaktadır.

Bu çalışmanın literatüre yapması beklenen en önemli katkılarından biri, mamografi raporlarındaki lezyonların her birinin, bulunduğu anatomik lokasyona göre ayrıştırılması ve lezyon özellikleri ile ilişkilendirilerek, hiç bir ek işlem gerektirmeden, bir karar destek sisteminde kullanılabilir şekilde yapılandırılmış olarak çıkartılmasıdır. Çalışmanın diğer bir önemli katkısı ise, metin halindeki raporlardan çıkartılan lezyon verilerinin bir karar destek sistemine direkt girdi olarak verilmesi sonucunda elde edilen çıktılar, manuel olarak hazırlanmış referans veri setinden elde edilen çıktılarla karşılaştırılmasının sunulması açısından bir ilk çalışma olmasıdır.

GENEL BİLGİLER

2.1. Meme Kanseri ve Mamografi

Önemli sağlık sorunlarından biri olan meme kanseri kadınlarda en sık rastlanan kanser türüdür [14-16]. Bunun yanı sıra, birçok ülkede özellikle de batı ülkelerinde kanserden olan ölümlerin başlıca nedenleri arasında sayılmaktadır [17-19]. Yapılan son çalışmalarda Amerika Birleşik Devletlerinde 2011 yılında 230.480 yeni meme kanser vakası ve 39.520 kadının meme kanserinden ölüm vakası olduğu tahmin edilmektedir [14]. Türkiye açısından bakıldığında ise; meme kanseri kadınlarda görülen en yaygın kanser türü olarak ifade edilmekte ve Sağlık Bakanlığı'nın 1999 yılı istatistiklerine göre görülme oranının %24,1 olduğuna işaret edilmektedir [20]. Özmen'in [21] 2008 yılında yaptığı araştırmada, Türkiye'de görülme sıklığının gün geçtikçe arttığı fakat ulusal ölçekte herhangi bir meme kanseri izleme programı olmadığı belirtilmiştir.

Meme kanserinden olan ölümlerin önlenmesi ve hastalığa yakalananların erken evrede teşhis edilmesi önemlidir [4-6]. Belirtilerin erken evrede teşhisinde klinik meme muayenesi yapılması, mamografi çektilmesi ve gerekli görüldüğü hallerde de ultrasonografi ve manyetik rezonans görüntüleme gibi ilave tarama yöntemlerinin kullanımının faydaları literatürde belirtilmiştir [4-7].

Rutin bir tarama tetkiki olarak kabul edilen mamografinin uygun tanı ve tedavilerle birlikte kullanıldığında, meme kanserinin erken dönemde teşhis edilmesindeki önemi ve meme kanserine bağlı olarak ortaya çıkan ölümlerin azaltılmasında etkili bir yöntem olduğu önceki çalışmalarda vurgulanmıştır [1-4].

2.1.1. Mamografi Yorumlarındaki Değişkenlik

Son yıllarda mamografi kullanımı artarken, birçok çalışmada uygulamalardaki gözlemler ya da gözlemciler (radyologlar) arası yüksek değişkenlik önemli bir sorun olarak vurgulanmıştır [5-9]. Mamografi incelemelerindeki değişkenlik hem lezyonların saptanmasında ve sınıflandırılmasında hem de mamografik incelemeyi izleyen süreçlerin belirlenmesinde ortaya çıkabilir. Mamografi incelemelerinde gözlemler ya da gözlemciler arasında ortaya çıkan bu değişkenlik önemli klinik ya da ekonomik sonuçlar doğurabilir [17].

Mamografi bulgularında radyologlar arası yorum farklılıklarından kaynaklanan değişkenliği azaltmak ve klinisyenlere net sonuçlar verebilmek için önemli bir yaklaşım mamografi raporlarında kullanılan terminolojinin standartlaştırılmasıdır. Bu amaçla, Breast Imaging Reporting and Data System (BI-RADS) isimli sınıflama sistemi geliştirilmiştir [22].

2.1.2. Breast Imaging Reporting and Data System (BI-RADS)

Mamografi raporlarındaki terminolojinin standardizasyonu, lezyonların standart kriterlere göre kategorizasyonu ve tarama mamografilerinde saptanan lezyonların izlem protokollerinin belirlenmesi amacıyla American College of Radiology (ACR) tarafından BI-RADS sınıflama sistemi geliştirilmiştir [22]. Tanımlamada sistem kelimesinin kullanılmasının nedeni, içeriğinde bir çok farklı bileşeni barındırmasıdır. Bu bileşenler, tanımlayıcılar için standart terimlerden oluşan bir sözlük, son değerlendirme ve değerlendirme sonrası yönetime ilişkin kategorileri içeren raporlama yapısı önerisi ve verilerin toplanması ve işlenmesi için bir çerçeveden oluşmaktadır [22].

BI-RADS geliştirme komitesi, uygun ve standartlaştırılmış terimlerin mamografi uygulamaları sırasında kullanımın önemini savunmakta ve mamografinin “karar yönelimli” olmasını önermektedir. Bu komite ayrıca, mamografi karar sürecindeki son değerlendirmenin her raporun sonunda bulunan önceden tanımlanmış ve takip önerileriyle de eşleştirilmiş değerlendirme kategorilerinden birisinin seçilerek yapılmasını önermektedir [22]. Bu amaçlarla, yoğunluk, lezyon özellikleri, bulgular ve öneriler için standartlaştırılmış terimler geliştirilmiştir [23]. Bu sistem aralıklı olarak değişikliğe uğramakta ve yorum birliğini sağlama açısından etkinliğini araştıran çalışmalarla test edilmektedir [22, 24-25]. En son sürüm olan sürüm 4’de yer alan değerlendirme kategorileri Tablo 1’de verilmiştir [22].

Çizelge 2.1. BIRADS tanı sınıflaması

Kategoriler	Tanımlamalar
Kategori 0	İlave görüntüleme yöntemlerine ihtiyaç var
Kategori 1	Normal mamogram
Kategori 2	Benin bulgular
Kategori 3	Muhtemelen benin bulgular
Kategori 4	Şüpheli bulgular
Kategori 4A	Hafif derecede kuşkulu
Kategori 4B	Orta derecede kuşkulu
Kategori 4C	İleri derecede kuşkulu
Kategori 5	Yüksek olasılık ile malignite düşündürülen bulgular

Yapılan çalışmalar BI-RADS sisteminin bazı kısıtlılıklarını ortaya çıkarmıştır [10-13]. BI-RADS sınıflandırma sistemi mamografi raporlama sürecinde ortaya çıkan değişkenliği azaltmada önemli bir adım olmasına rağmen, karar verme sürecinde değişkenliği azaltmada ve radyologların elde ettikleri bulguları olası tanımlarla nasıl ilişkilendirecekleri konusunda yetersiz kalmaktadır [26]. Örneğin, bir değerlendirme çalışmasında BI-RADS son değerlendirme kriterlerinden biri olan kategori 3’e ait izlem önerilerinde büyük değişkenlik saptanmış, bu kategorideki vakaların %37’sine kısa süreli takip yerine ek görüntüleme yöntemlerinin istemi yapıldığı görülmüştür [26]. Lai ve arkadaşlarının çalışmalarında ise radyologlar arasında kategori 3 ve 5 için uyumlu değerlendirmeler sağlansa da kategori 4’e

ilişkin farklılıklar saptanmıştır [12]. Buna ek olarak aynı çalışmada, radyologlar arası uyumun radyologların uzmanlık düzeyi ile doğru orantılı olduğu belirtilmiştir.

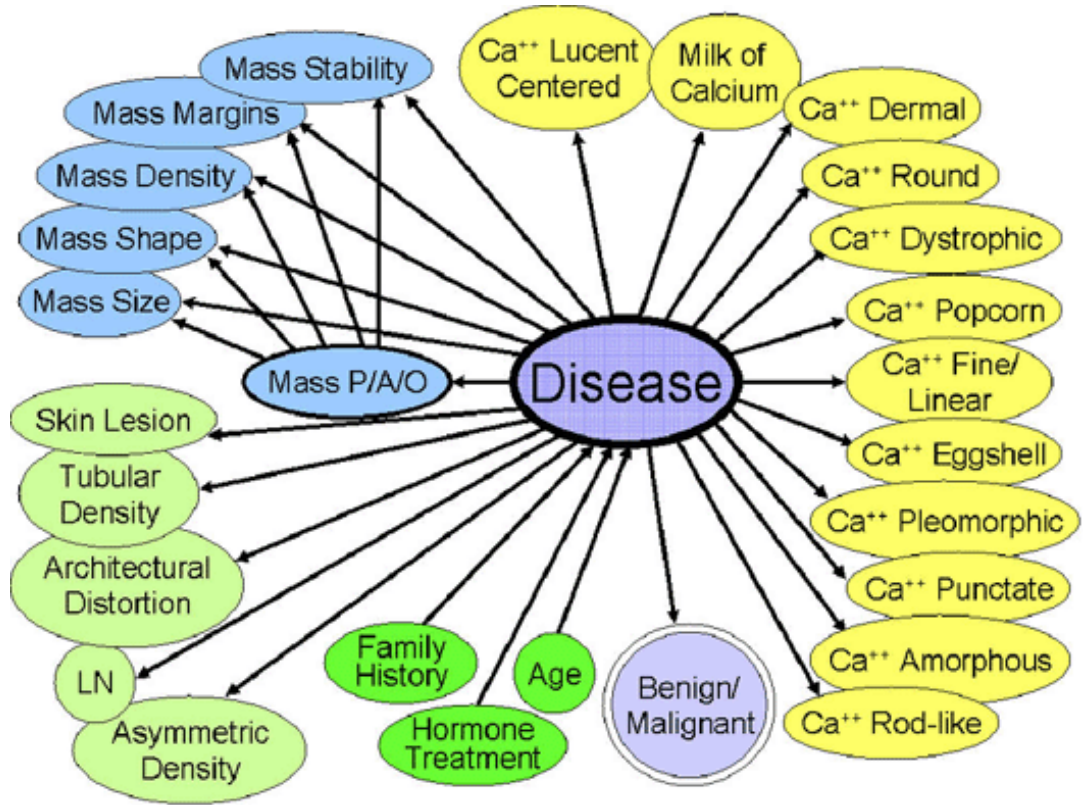
BI-RADS sisteminin en önemli kısıtlarından biri de bu sistemin radyologlara bulgularını tanımlarla nasıl ilişkilendireceklerini belirtmemesidir. BI-RADS sistemi gözlemlenen veri setleri için malignite olasılığını tanımlamada ve sonraki adımları seçmede yardımcı olmaz. Bu noktalardaki değerlendirme ve yorum farklılıkları mamografi karar süreçlerindeki istenilmeyen değişkenliğin nedenini oluşturur [25, 27]. Uygulamadaki bu gibi yetersizlikler radyolojik değerlendirme performansını yükseltmeye yardımcı olan karar destek sistemlerinin geliştirilmesi için fırsatlar sunmaktadır.

2.2. Klinik Karar Destek Sistemleri

Bilgi teknolojilerinin önemli katkısıyla, hastaya ait diğer sağlık verileri ile, mamografi bulgularının birlikte kullanıldığı bilgisayar tabanlı karar destek sistemleri geliştirilmiş ve bu sistemlerin olumlu sonuçları geçmiş çalışmalarda belirtilmiştir [7, 28-33]. Benzer şekilde, mamografi değerlendirme sürecinde kullanılmak üzere geliştirilmiş karar destek sistemlerinin olumlu sonuçları da geçmiş çalışmalarda belirtilmiştir [29, 34-37]. Mamografik bulgulara ek olarak hastaya ait diğer risk faktörlerinin de hasta sağlık kayıtlarından elde edilmesi ve mamografi bulgularıyla bütünleştirilerek karar verilmesi önemlidir. Ancak bu şekilde her bir hasta için farklı veri kaynaklarından toplanan veriler ve risk faktörlerinin değişik kombinasyonları ile risk tahmin modelleri oluşturulabilir.

Karar destek sistemlerinin temelini matematiksel modeller ve veri madenciliği yöntemleri oluşturur [38-39]. Literatürde meme kanseri riskini hesaplamak için oluşturulmuş bir çok risk modeli bulunmaktadır [29, 34-37, 40-43]. Bu risk modelleri, her hasta için risk olasılığı tahminleri üretir. Bu modellerin bilgisayar destekli karar destek sistemleri ile kullanımı mamografi karar sürecinde fayda sağlamaktadır [35]. Farklı risk tahmin modellerini kullanarak hazırlanmış bir çok web ya da bilgisayar tabanlı araç geliştirilmiştir [29-32, 40]. Fakat bunların sadece birkaçında BI-RADS sınıflandırma sisteminden yararlanılmaktadır. Oysa ki BI-RADS sınıflandırma sisteminde yer alan tanımlayıcılar modelde girdi olarak kullanıldığında pozitif tahmin değerinde artış sağlandığı görülmüştür [29].

Burnside ve arkadaşları 2000 yılından bu yana BI-RADS sınıflandırma sistemi, bu sistemin karar modellerine entegrasyonu ve geliştirilen modellerin bilgisayar destekli olarak kullanımı üzerinde birçok çalışma yapmaktadırlar [22, 34-37, 44]. Burnside, Stanford Üniversitesi'nden Rubin ile birlikte mamografi sürecinde karar destek sistemi olarak kullanılmak üzere BI-RADS terminolojisini de kullanan bir Bayes ağ modeli geliştirmiştir ve geliştirilen modelin yüksek duyarlılık ve seçicilik değerleriyle tahminleme yapabildiği saptanmıştır [34, 36-37]. Literatürde bu üç çalışma dışında, BI-RADS terminolojisini içeren bir model kullanan herhangi bir bilgisayar ya da web tabanlı karar destek sistemi bulunmamaktadır. Var olan bu sistem de Stanford Üniversitesi Görüntüleme Bilişimi Laboratuvarında Rubin ve arkadaşları tarafından geliştirilmeye devam etmektedir. Bu model Şekil 2.1'de gösterilmiştir.



Şekil 2.1. Mamografi tanıları için geliştirilen Bayes Ağ Modeli [34]: Mavi renkli düğümler kitle ve bu kitleye ait özellikleri, sarı renkli düğümler kalsifikasyonları, koyu yeşil renkli düğümler hastanın hikayesinden elde edilen verileri, açık yeşil renkli düğümler ek gözlemleri, Disease düğümü hastalık tanısını, Benign/Malignant düğümü ise bayes ağının tahminleyeceği çıktı olan benin ya da malin olma durumunu temsil etmektedir.

2.2.1. Klinik Karar Destek Sistemlerinin Yetersizlikleri

Bugüne kadar geliştirilmiş klinik karar destek sistemleri hekimlerin günlük rutin uygulamalarında aktif şekilde kullanılamamaktadır. Bu duruma hekimlerin iş yükü, direnci ya da karar destek sistemlerinin düşük kullanılabilirlik seviyesi gibi birçok neden gösterilebilir [45].

Karar destek sistemlerinin hekimlerin günlük rutin uygulamaları sırasındaki kullanımını arttırmak “gerçek zamanlı” karar destek sistemlerinin geliştirilmesiyle mümkün olabilir. Çünkü, gerçek zamanlı karar destek sisteminin kullanımı nedeniyle zaman kaybı olmamakta, sistemdeki veriler insan emeği olmadan kullanılabilir. Literatürde “gerçek zamanlı” klinik karar destek sistemleriyle ilgili çok az sayıda çalışma bulunmakla birlikte, bu çalışmalar gelecek çalışmalar için motivasyon sağlamaktadır [46].

Literatürde, karar destek sistemlerinin klinik uygulamaları geliştirilmesiyle ilişkili dört temel özellik:

- 1) klinik iş akışının bir parçası olarak otomatik bir şekilde,
- 2) karar verme anında ve yerinde,

- 3) gerçekleştirilebilir önerilerle ve
- 4) bilgisayar tabanlı olarak karar desteği sağlama olarak belirlenmiştir [47].

Fakat, mamografi değerlendirme süreci için geliştirilmiş karar destek sistemlerinin hiç biri “gerçek zamanlı” değildir ve karar destek sistemlerinin klinik uygulamaları geliştirmesiyle ilişkili dört temel özelliğin tümünü birden sağlamamaktadır.

2.2.2. Gerçek Zamanlı Karar Destek Sistemleri (GZ-KDS)

Rutin bir hasta bakım sürecinde, hekimler hastaya ait laboratuvar sonuçları, daha önce kullandığı ilaçlar, yaşam kalitesi skorları gibi bir çok veriye ihtiyaç duymanın yanı sıra, bu sağlık kayıtlarını incelemek için de önemli miktarda zaman harcamaktadırlar ve kendilerini zaman kaybettireceğini düşündükleri uygulamaları kullanmaya karşı direnç göstermektedirler [46, 48]. Hekimler ancak hızlı, kullanımı kolay, kullanıcı ihtiyaçlarına göre geliştirilmiş ve iş akışına entegre edilebilme özelliklerine sahip karar destek sistemlerini kabul edeceklerdir. Bu nedenle de, karar destek sistemlerinin hekimlerin günlük rutin uygulamaları sırasındaki kullanımını arttırmak “gerçek zamanlı” karar destek sistemlerinin geliştirilmesiyle mümkün olabilir, çünkü karar destek sisteminin kullanımı nedeniyle zaman kaybı olmamakta, sistemdeki veriler insan emeği olmadan kullanılabilir [46].

Gerçek zamanlı karar destek sistemleri, veri kaydı sırasında veriyi anında kullanır, kural tabanlı ya da diğer mantıksal çıkarım modelleriyle analiz eder ve son kullanıcı tarafından kullanıma uygun hastaya özel bulguları anında, otomatik olarak sunar [33, 48]. Örneğin, Fitzgerald ve arkadaşları, hasta monitörlerinden ve hemşirelerin el bilgisayarlarından girdiği veriyi anında girdi olarak alıp analiz eden gerçek zamanlı bir karar destek sistemi geliştirmişler ve bu sistemin kullanımının önemli hataları azalttığını gözlemlemişlerdir [49]. Benzer şekilde, Zheng ve arkadaşlarının 2012 yılında geliştirdikleri gerçek zamanlı karar destek sistemi de [50], veri akışı madenciliği sistemi (data stream mining system) ile veri akışı sırasında veriyi toplayıp, çıkarımlar sağlayan, henüz prototip düzeyinde bir GZ-KDS örneğidir ve değerlendirmesi bulunmamaktadır. Fakat, bu çalışmada vurgulanan GZ-KDS'lerin arka planında kullanılan algoritmaların hızının da önemi göz önünde bulundurulmalıdır. Bir diğer pilot sistem de Lin ve arkadaşları tarafından prostat kanseri tedavisinde gerçek zamanlı karar destek sağlamak amacıyla geliştirilmiştir ve bu sistemin hekimlerin hastayla ilgili bulguları kolayca görüntülemesi, sunması, risk tahminleri yapması gibi kolaylıklar sağladığı vurgulanmıştır [46]. Klinik karar destek sistemlerinin değerlendirilmesiyle ilgili bir çok çalışma bulunsa da, GZ-KDS'ler ile ilgili pilot düzeyde kalan çalışmalar GZ-KDS'lerin klinisyenler tarafından, iş akışları içerisinde kullanımını raporlayan yeterli çalışma bulunmadığını göstermektedir [52].

GZ-KDS'lerin önemli bileşenlerinden biri de, girdi verisini otomatik olarak toplaması, herhangi bir veri girişi gerektirmemesi ve verinin istenildiği anda kullanılmasına izin vermesidir. Karar destek için kullanılacak gerekli veriyi toplama amacıyla kullanılan yöntemler veri kaynağına göre değişmekle birlikte, özellikle radyoloji alanında olduğu gibi verilerin raporlar halinde sunulduğu durumlarda,

yapılandırılmamış metinden bilgi çıkarımı için doğal dil işleme yöntemlerinin kullanımı dikkat çekmektedir [51].

2.2.3. Karar Destek Sistemlerine Veri Sağlamak Amacıyla Doğal Dil İşleme Yöntemlerinin Kullanılması

Karar destek sistemleri için gerekli veri, sisteme manuel olarak hekimler tarafından girilebilir fakat bu durum hekimlerin sistemi sadece ihtiyaç hissettikleri durumlarda ve veriyi bulmak ve girmek için zaman ayırabildikleri koşullarda kullanmalarına yol açar. Oysa ki, otomatik olarak veriye ulaşabilen, dikkat çekilmesi gereken bir durum oluştuğunda kendiliğinden hatırlatıcı ve uyarıcılar sağlayan bir karar destek sistemi çok daha etkin olacaktır [52].

Günümüzde, ulusal ve uluslararası ölçekte, hastalara ait gözlemlerin bir çoğu, örneğin radyoloji raporları, operasyon notları, taburcu bilgileri v.b. yapılandırılmamış ya da yarı yapılandırılmış metinler halindedir. Bu format, hem bilginin saklanması, hem de aktarılması amacı ile yaygın olarak kullanılmaktadır. Radyoloji, patoloji, nükleer tıp ve daha birçok tıbbi disiplin, verinin kaydedilme ve iletilme yolu olarak neredeyse tamamen yapılandırılmamış serbest metinlere dayanmaktadır. Bu serbest metin içerisinde kayıtlı bilginin sağlık bakım hizmetlerinin iyileştirilmesi, verimliliğinin ve kalitenin artırılması, tıbbi araştırmalar ve eğitim gibi amaçlarda kullanılması için değerli bir kaynaktır. Bu nedenle, bir çok karar destek sistemi için gerekli verinin bu metinlerden elde edilmesi gerekmektedir. Bu gereksinim, doğal dil işleme teknikleri kullanılarak otomatik olarak, kısa sürede ve az maliyetle sağlanabilir [52].

2.3. Doğal Dil İşleme

Doğal Dil İşleme (DDİ) ana işlevi bir doğal dili çözümlenme, anlama, yorumlama ve üretme olan bilgisayar sistemlerinin tasarımını ve gerçekleştirilmesini konu alan bir mühendislik alanıdır [53]. 1950 ve 1960'larda yapay zekanın küçük bir alt alanı olarak görülen bu konu, araştırmacıların ve gerçekleştirilen uygulamaların elde ettiği başarılar sonunda artık bilgisayar bilimlerinin temel bir disiplini olarak kabul edilmektedir [54].

DDİ, doğal dillerin kurallı yapısının çözümlenerek anlaşılması veya yeniden üretilmesi amacını taşır ve örnek uygulama alanları aşağıda sıralanmıştır [52-53, 55-57]:

- Yazım yardımcı araçlarının geliştirilmesi
- Yazım yanlışlarının düzeltilmesi
- Bul ve değiştir
- Basılı bir metni okuma (optik olarak metin okuma) ve okuma yanlışlarını düzeltme
- Bir metnin özetini çıkarma
- Metnin içerdiği bilgiyi çıkarma
- Bilgiye erişim

- Metni anlama
- Bilgisayarla sesli etkileşim
- Bilgisayarın konuşması (metni seslendirme)
- Konuşmayı anlama (konuşmayı metne dönüştürme)
- Soru yanıt dizgeleri
- Yabancı dil okuma yardımcı araçları
- Yabancı dilde yazma yardımcı araçları
- Doğal diller arası çeviri

Karar destek sistemleri için gerekli veriyi hasta raporlarından otomatik olarak sağlama da DDİ uygulama alanlarından, metnin içerdiği bilgiyi çıkarmaya girmektedir (51-54).

2.3.1. Metinden Bilgi Çıkarımı (Information Extraction)

Bilgi Çıkarımı (BÇ), doğal dille yazılmış metinler içinde, önceden belirlenmiş olaylar ya da ilişki sınıflarına ait nesnelere ve bunlara ait uygun parametrelerin belirlenmesidir [55]. Bu sistemler doğal dille yazılmış dokümanlarda bulunan belirli veri parçalarıyla ilgilenmektedir. Yani yapılandırılmamış metinlerden yapılandırılmış bilgiyi çıkarmaya çalışmaktadırlar. Sistemler genellikle yapılandırılmamış metinleri veritabanı tablosuna aktarılabilecek bir formata dönüştürmektedirler [55-57].

Metin içerisindeki kelimeleri bulmayı ve sınıflandırmayı amaçlayan bilgi çıkarımının ön koşulu; "isimlendirilmiş varlık tanıma (Named Entity Recognition, NER)", yani önceden belirlenmiş kategorilere göre varlıkların tanımlanması ve isimlendirilmesidir (kişi isimleri, organizasyonlar, yerler vb.) [58]. Bu süreçte önceden tanımlanmış kavramlar, varlıklar, ontolojiler ve terminolojiler önemli rol almaktadır.

Bilgi çıkarımı sistemlerinin sonuçlarının değerlendirilmesinde, bilgi erişim sistemlerinde de olduğu gibi kesinlik (precision) ve hassasiyet (recall) ölçütleri kullanılmaktadır. Fakat burada belgeler yerine, yapılan tahminler ölçüm değişkenleri olarak kullanılmaktadır.

Tıp alanına özel geliştirilmiş, MedLEE [64], SymText [65], cTAKES [66], HITEx [67], caTIES [68], KnowledgeMap [69], MEDSYNDIKATE [70], ve MetaMap [71] gibi birçok doğal dil işleme uygulaması bulunmaktadır [51, 59]. Bu sistemlerin yapılandırılmamış metin halindeki sağlık kayıtlarından bilgi çıkarımı problemini çözmek için kullanıldığı konulara örnek olarak kritik izlem önerilerinin tanımlanması [67-68], pnömonin saptanması [65], anatomik lokasyon kalıplarının indekslenmesi [66], tümör konumunun saptanması [69], kemik kırığı (bone fracture) bilgisinin otomatik çıkartılması [70], kullanılan ya da bahsi geçen ekipmanların saptanması [71], hastalığa özel kritik bulguların alıntılanması [72] verilebilir. Genel olarak bu sistemler, sözdizimsel yapıları (örn: cümle, sözcük, bölüm, sözcüğün dilbilimsel özellikleri gibi) tanımlar, isimlendirilmiş varlıkları arar ve tanıır, kavramları tanımlar ve terminoloji ile eşleştirir (ilaçlar, tedaviler vb.) ayrıca sözcüklere ait olumluluk/olumsuzluk gibi özellikleri saptar [65].

2.3.2. Mamografi Raporlarından Bilgi Çıkarımı

Şimdiye kadar yapılan çalışmalar arasında sadece birkaçı mamografi raporlarından bilgi çıkarımına odaklanmıştır [65-69].

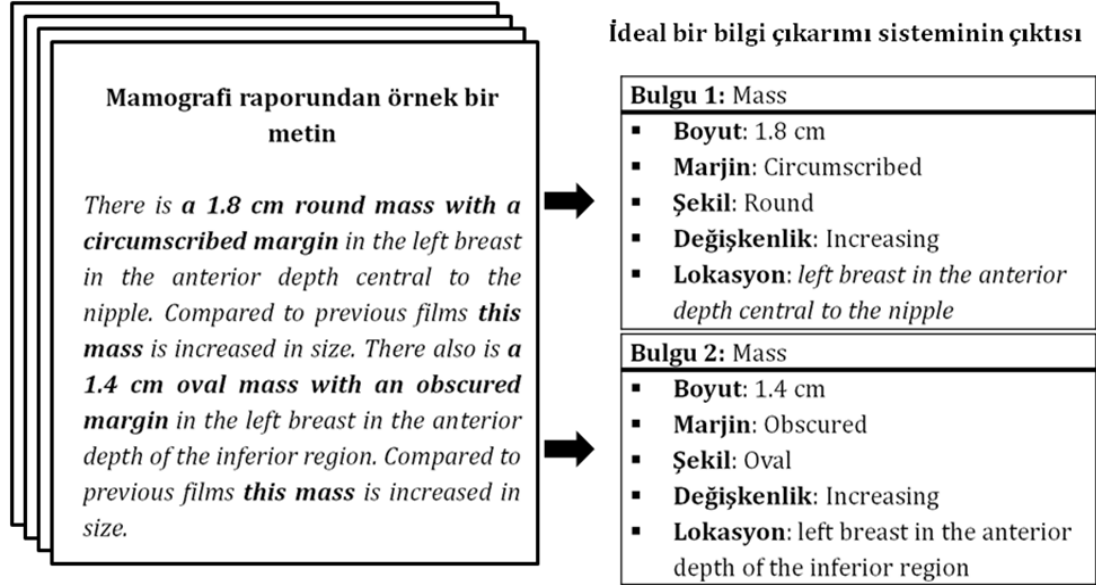
Mammografi raporları bir çok açıdan diğer sağlık kaydı metinlerinden (narrative texts) farklıdır. Öncelikle BI-RADS içerisinde tanımlanmış olan özel bir terminoloji yani isimlendirilmiş varlıklar (named entities) listesi içerir [22, 24, 60]. Ayrıca, mammografi raporlarından çıkarılması amaçlanan bilgiler de bu alana özeldir. Daha detaylı olarak açıklanacak olursa, mamografi raporlarından istenilen bilgilerin çıkarılması için öncelikle mammografiye ait gözlemlerin (imaging observations) ve bunların birbirleriyle olan ilişkilerinin tanımlanması (örn: lezyonun boyutu ve memedeki lokasyonu) gerekmektedir. Bu aşamada özellikle, bir raporda birden fazla lezyondan bahsedilmiş olabileceğinden, hangi özelliklerin hangi lezyona ait olduğunun uygun şekilde ilişkilendirilebilmesi gerekmektedir. Bu özelliklerinden dolayı mamografi raporları daha önceden daha genel amaçlarla ya da başka alanlara özel sistemlere direkt girdi olarak verilip analiz edilememektedir ve mammografiye özel tasarlanmış sistemler gerektirmektedir [29, 35, 61-64].

Nassif ve arkadaşları [63], mamografi raporlarında BI-RADS'te tanımlanmış kavramları bulan bir sistem geliştirmişler, fakat bu kavramlar arasındaki ilişkileri incelememişlerdir. Benzer şekilde, Jain ve arkadaşları meme kanseri şüphesine ait bilgileri tanımlamak için MedLEE isimli sistemi kullanmışlardır [70-71]. MedLEE gözlemler ile anatomik lokasyonları ilişkilendirme altyapısına sahip olmadığından Sevenster ve arkadaşları [70] yine MedLEE tabanlı bir sistem geliştirerek radyoloji raporlarındaki gözlemler ile bu gözlemlerin ait olduğu lokasyonlara ait bilgileri eşleştirebilen bir sistem geliştirmişlerdir. Bu çalışmanın bulgularında, bir lokasyona ya da bulguya dair birden fazla tanımlayıcı (modifier) var ise (örn: upper inner quadrant of the left breast), MedLEE'nin bu kavramları saptamada yetersiz kaldığı, sisteme yeni terimler eklense de sistemin temelini oluşturan kuralların değiştirilmesi gerektiği sonucuna varmışlardır. Fakat MedLEE açık kaynak kodlu bir sistem olmadığı için, modifikasyonunu gerçekleştiremediklerini belirtmişlerdir [70].

Bugüne kadar geliştirilen doğal dil işleme ile bilgi çıkarımı sistemlerinin en önemli limitlerinden biri, bu sistemlerin, örneğin aynı memede, birden çok lezyona ait bilginin var olduğu durumlarda, birbirinden farklı lezyonları ayırt edememeleri ve her bir lezyonla ilgili özelliği ilişkilendirememeleridir [54]. Bu durum özellikle mamografi raporlarında önemli bir problemdir, çünkü raporda bir kavram, örneğin kitle (mass), aynı ya da farklı kitleleri belirtmek için bir çok kez kullanılabilir. Bu nedenle, mamografi raporunda bir lezyondan ya da bulgudan bahsedildiğinde, aynı lezyondan mı farklı lezyondan mı bahsedildiğini tanımlayabilmek önemlidir.

Şekil 2.2'de iki ayrı lezyonun ve bu lezyonların marjin, değişkenlik ve şekil gibi farklı özelliklerinin tanımlandığı bir rapor örneği görülmektedir. Düz metin halinde olan bu rapor örneğinden çıkartılması istenen gözlemler ve bu bilgilerin yapılandırılmış hali de şekilde gösterilmiştir. Rapor içerisinde, farklı lokasyonlarda bulunan iki farklı kitleden bahsedilmekte ve bu kitlelerin özellikleri tanımlanmaktadır. Bilgi çıkarımı sırasında bu kitlelerin birbirinden farklı olduğunun, her birinin farklı bir lokasyonda bulunduğu ve ayrı özelliklere sahip olduğunun saptanabilmesi, doğru bir sonuca ulaşılabilmesi için gereklidir. Bu sonuca

ulaşabilmek için bu çalışmadaki gibi ileri düzey bilgi çıkarımı sistemlerine ihtiyaç olacaktır.



Şekil 2.2. İki ayrı lezyonun ve bu lezyonların marjin, değişkenlik ve şekil gibi farklı özelliklerinin tanımlandığı bir rapor örneği ile KDS'de kullanılmak üzere DDİ sisteminden elde edilmesi istenen çıktı

GEREÇ VE YÖNTEM

Bu bölümde mamografi raporlarının hangi alanlardan oluştuğu, sistemin geliştirilme aşamasında kullanılan yöntemler, oluşturulan kelime listeleri ve süreç içerisinde izlenen adımlar anlatılmıştır.

Çalışma dört ana bölümden oluşmaktadır:

1. Karar destek sistemi için gerekli olan yapılandırılmış verinin yapılandırılmamış ya da yarı yapılandırılmış metin halindeki mamografi raporlarından çıkartılması,
2. Doğal dil işleme teknikleri kullanılarak çıkartılan yapılandırılmış verinin referans veri seti ile karşılaştırılarak kesinlik ve hassasiyetinin değerlendirilmesi,
3. Otomatik veri çıkarımı ile mamografi raporlarından elde edilen verinin karar destek sisteminde kullanılması,
4. Mamografi raporlarından otomatik olarak çıkartılan veri seti ile radyologlar tarafından hazırlanan referans veri seti girdi olarak verildiğinde, karar destek sisteminden her bir veri seti için elde edilen sonuçların karşılaştırılması.

3.1. Veri Seti

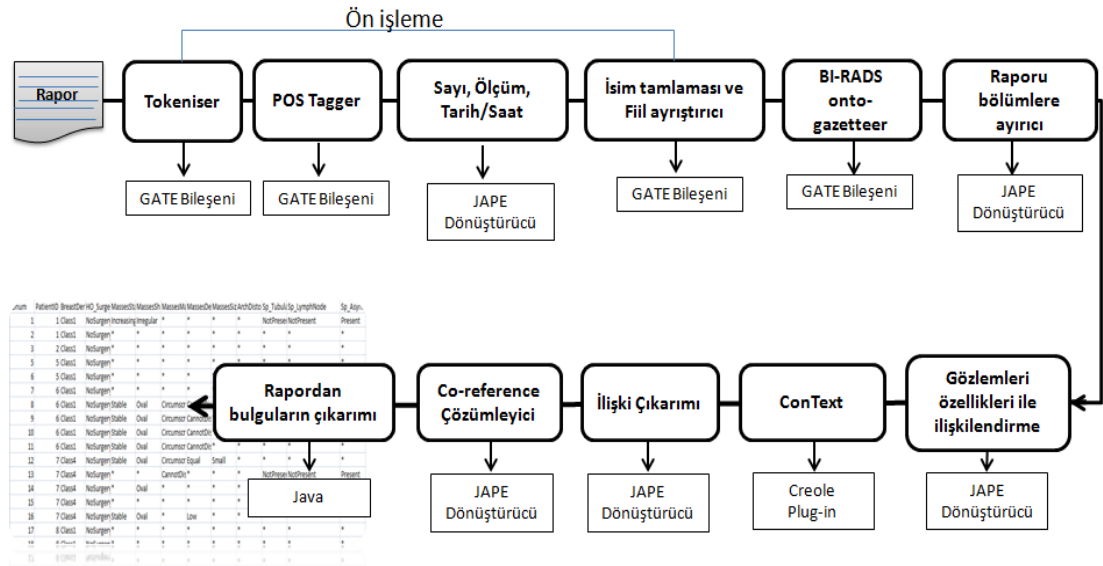
Otomatik bilgi çıkarımı sistemini geliştirmek için Stanford Üniversitesi görüntü bilişimi laboratuvarının kullanımına sunulmuş olan ve yapılandırılmış raporlama uygulamasını da destekleyen PenRad (PenRad, Buffalo, MN) isimli radyoloji veri tabanından 500 mamografi raporu seçilmiştir. Rapor setinin oluşturulması sırasında tek kriter, beninden yüksek ölçüde şüpheli maline kadar tüm BI-RADS sınıflandırma kodlarının kapsanması olarak belirlenmiştir.

Kullanılan raporlama sisteminde bir rapora ait hem yapılandırılmış veri alanları şeklinde, hem de yapılandırılmamış düz metin halinde kayıtlar bulunmakta olup bu sayede, yapılandırılmış veri çıktısı için referans veri seti sistemden otomatik olarak alınmıştır. Fakat sistemin bir kısıtı olarak, yapılandırılmış formatın raporların ilk haline ait olması ve sonradan yapılan düzeltmelerin sadece yapılandırılmamış metin üzerinde olması nedeniyle yapılandırılmış veri ile düz metin arasındaki tutarsızlıkları engellemek ve en uygun referans veri setini oluşturmak için iki radyolog tarafından referans veri seti kontrol edilerek düzeltilmiştir.

Rapor veri tabanından sadece BI-RADS sınıflandırma kodları dikkate alınarak rastgele seçilen 500 raporun 200 tanesi sistemin planlanması ve geliştirilmesi aşamalarında, geri kalan 300 rapor ise sistemin değerlendirilmesi için kullanılmıştır.

3.2. Karar Destek için Gerekli Olan Yapılandırılmış Verinin Mamografi Raporlarından Çıkarılması

DDİ sistemlerinin geliştirilmesinde kullanılan genel strateji, doğal dil işleme sürecini birbirinden farklı alt bileşenlere ayırarak gerçekleştirmektir. Bu alt parçalar birbirleri ile belirli bir sıralama oluşturacak şekilde bağlantılı olarak çalışır ve bu akış sonunda asıl amaçlanan üst düzey doğal dil işleme görevi yerine getirilir [65]. Benzer şekilde, mamografi raporlarından karar destek sisteminde kullanılmak üzere bilgi çıkarma süreci, alt düzeylere ayrılmış ve her bir düzey için farklı bileşenler geliştirilerek belirli bir sıralama izleyen bir ardışık düzen (pipeline) oluşturulmuştur. Oluşturulan ardışık düzen Şekil 3.1'de gösterilmiştir.



Şekil 3.1. Bilgi çıkarımı sürecinde kullanılan ardışık düzen

Bir mamografi raporunda birden fazla lezyon tanımlanmış olabileceğinden, her bir lezyonu birbirinden ayırıp bu lezyonlara ait özelliklerle ilişkilendirme işlemi zorlu bir süreçtir. Geliştirilen sistemde bu zorluğa çözüm sağlama amacıyla, iki ayrı lezyon aynı lokasyonda bulunamayacağından, lezyonların anatomik lokasyonlarına göre birbirlerinden ayrılması yaklaşımı kullanılmıştır.

3.2.1. DDI ile Çıkarılacak Bilgiye ait Temel Kavramların Sunumu (Knowledge Representation)

Bilgi çıkarımı işlemi üç temel kavrama (varlık) odaklanmaktadır: gözlemler (imaging observations), bu gözlemlere ait özellikler (modifiers of imaging observations) ve anatomik lokasyonlar (anatomic locations of imaging observations).

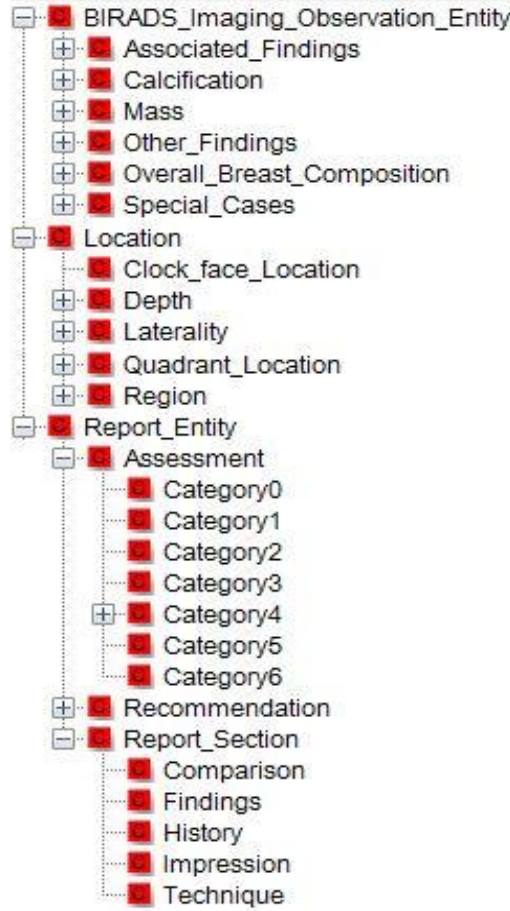
Gözlemler (imaging observations), memedeki kitle (mass) ya da kalsifikasyon (calcification) gibi anomalileri belirten terimlerdir. Bu gözlemlerin karakteristikleri (niteleyicileri) de, memedeki lezyonun sınır özellikleri, şekli, sabitliği gibi özelliklerini tanımlayan terimlerdir. Anatomik lokasyonlar ise lezyonların görüldüğü meme alanlarını tanımlayan terimlerdir. Bu kavramların amaca uygun şekilde metinden çıkartılabilmesi için, birbirleri ile olan ilişkileri ile birlikte detaylı şekilde tanımlanmaları gerekmektedir. Bu amaçla, sistemi geliştirmeden önce yapılan bu tanımlamalar Çizelge 3.1'de verilmiştir. Anatomik lokasyonlar da "saat yönü, kadran" gibi tanımlayıcı özelliklere sahiptirler.

Çizelge 3.1. Mamografi raporlarından çıkarılmak üzere tanımlanan varlık tipleri ve birbirleriyle olan ilişkileri

Varlık Tipi (Entity Type)	Tanımlama	Örnek
Gözlemler	Durum, koşul, problem vb.	<i>The breast, overall, demonstrates no focal dominant mass, <u>architectural distortion</u>, or <u>suspicious calcifications</u>.</i>
Lokasyon	Gözleme ait anatomik lokasyon	<i>The breast, overall, demonstrates no focal dominant mass, <u>architectural distortion</u>, or <u>suspicious calcifications</u>.</i>
Lokasyon Özellikleri	Anatomik lokasyonun yön, derinlik gibi özellikleri	<u>right</u> breast <u>12 o'clock position</u> <u>anterior depth</u> <u>upper</u> breast <u>central region</u> <u>1 cm</u> from the nipple
Gözlemlerin Özellikleri	Gözlemlere ait durum bildiren özellikler	<u>stable</u> focal asymmetric density <u>spiculated</u> mass <u>irregularly-shaped</u> mass breast tissue is <u>largely fatty</u> <u>10 x 6 x 10 mm</u> mass

Çizelge 3.1'deki varlıklar tanımladıktan sonra bu varlıklara ait tüm terimlerin sağlanması için BI-RADS terminolojisi kullanılmıştır [24]. BI-RADS yapılandırılmış

bir formatta hazır bulunmadığından, geliştirilecek sistemin bilgi altyapısını oluşturmak üzere BI-RADS terminolojisinden basit ölçekte bir ontoloji hazırlanarak, hazırlanan BI-RADS ontolojisinde, varlıklar arasında "is-a" hiyerarşileri ve bu varlıklara ait özellikler (attributes) tanımlanmıştır (Şekil 3.2). Ayrıca, BI-RADS içinde yer alan kavramların eş anlamlıları ve kullanılan bazı kısaltmalara ait kelime listeleri bir uzman yardımıyla 100 örnek rapor incelenerek belirlenmiştir.



Şekil 3.2. BI-RADS ontolojisi. Varlık isimleri ve birbirleriyle olan ilişkileri.

3.2.2. Bilgi Çıkarımı Sürecinde Kullanılan Ardışık Düzen (Processing Pipeline)

Şekil 3.1'de gösterilmiş olan ardışık düzenin geliştirilmesi aşamasında GATE NLP (General Architecture for Text Engineering) isimli DDİ ortamı kullanılmıştır [66]. GATE NLP, Sheffield Üniversitesi'nin geliştirdiği bir DDİ projesi olup doğal dil işleme uygulamaları için açık kaynak kodlu bir çerçeve, kütüphaneler, ve üzerinde değişiklik yapılabilen çeşitli (örn: metni sözcüklere ayıran, metin içerisindeki sayıları ayıran vb) doğal dil işleme kaynakları sunar (processing resources). Bu kaynaklardan biri de Gazetter olarak isimlendirilen ve önceden tanımlanmış listeler içerisindeki kelimeleri metin içerisinden bulup "lookup" anotasyon şeklinde işaretleyen işleme kaynağıdır [66]. Bunlara ek olarak, GATE

düzenli ifade kalıplarını (pattern) (örn: telefon numarası "232 231 51 00") bulmak amacıyla gerekli kalıp/ifade tanımlamalarının yapılabilmesi için Java Annotation Patterns Engine (JAPE) isimli bir patern eşleme motorunu destekler [66].

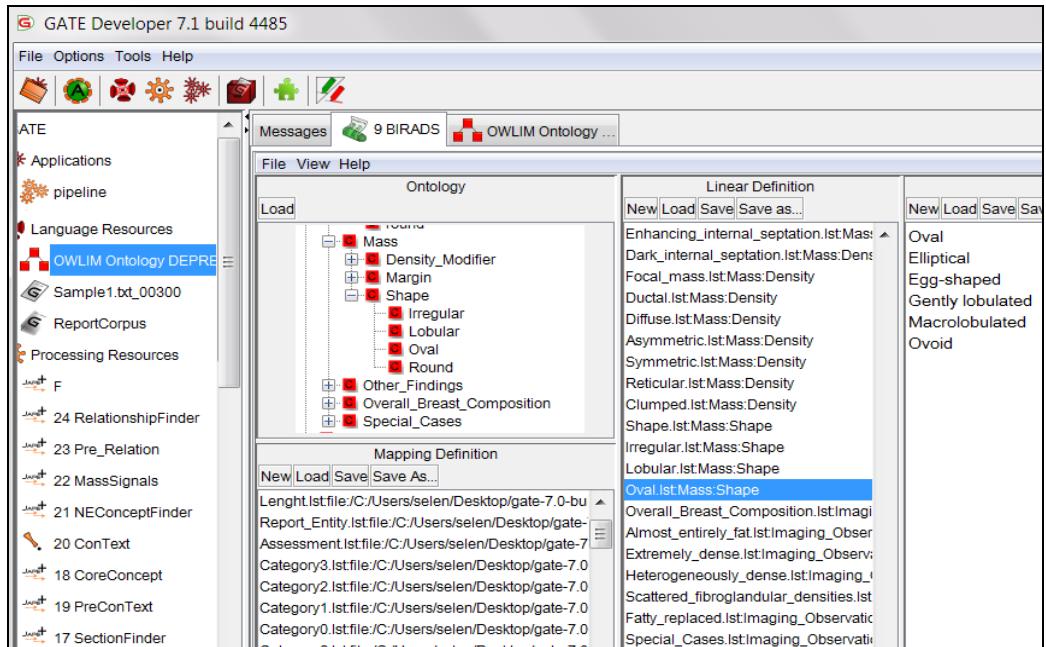
Şekil 3.1'de gösterilen ardışık düzende yer alan işleme modülleri, mamografi raporlarını işleyerek bu raporlardan karar destek sistemi için gerekli yapılandırılmış verinin çıkarılmasını sağlamaktadır. Her modül, ayrı bir alt işlemi gerçekleştirerek asıl amaca hizmet eder. Bu modüller aşağıda detaylı olarak tanımlanmıştır.

1. Ön işleme (Kelimelere ve cümlelere ayırma, kelimelerin dilbilimsel özelliklerinin belirlenmesi, sayı/ölçüm/tarih bildiren kelimelerin ayrıştırılması):

Bu aşamada GATE NLP çatısı altında kullanılmak üzere hazırlanmış ve değerlendirmesi yapılarak etkinliği ispatlanmış GATE modülleri kullanılarak gerekli ön işleme uygulanmıştır. Ön işleme modülleri ile metin kelimelere ayrılmış, kelimelerin dilbilimsel özellikleri atanmış, sayılar ve noktalama işaretleri, kelime kökleri saptanmış, cümle sınırları belirlenmiş, isim tamlamaları ve fiiller ayrıştırılmıştır. Ayrıca, ölçümleri ve tarihleri tanımlayan modül ile de metin içerisinde ölçüm veya tarih bildiren ifadeler işaretlenmiştir.

2. BI-RADS onto-gazetteer:

Bu modül metin içerisinde yer alan terimleri BI-RADS ontolojisi ile eşleştirir. Bu amaçla GATE için geliştirilmiş olan Onto-Gazetteer BI-RADS ontolojisi ile entegre edilerek kullanılmıştır (Şekil 3.3).



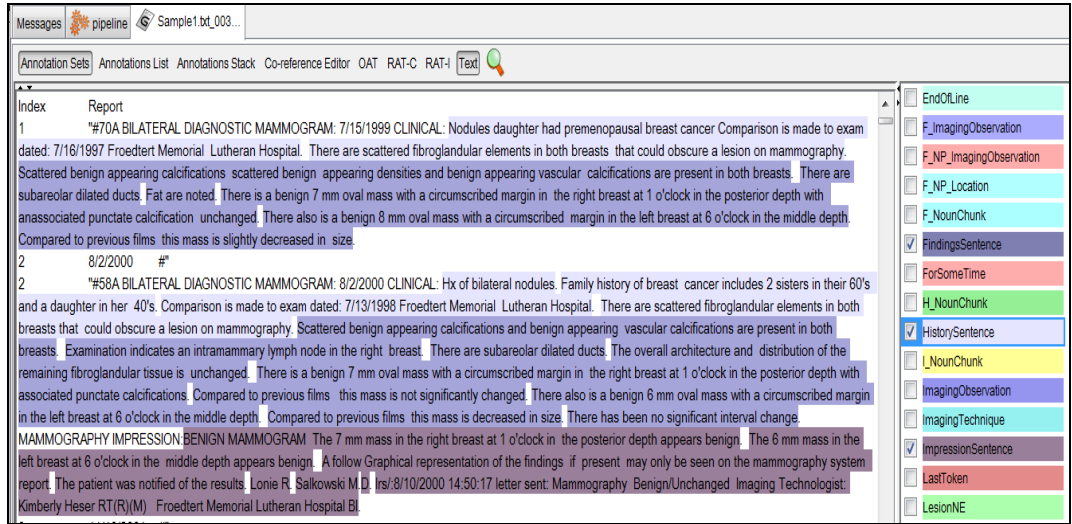
Şekil 3.3. BI-RADS Onto-Gazetteer uygulamasının ile GATE NLP ortamında kullanımına ait ekran görüntüsü

Bu araç, tanımlanan listelerdeki terimleri metindeki terimlerle eşleştirirken aynı zamanda bu terimlerin ontolojide ait oldukları sınıfları da tanımlar ve her terim için bir sınıf numarası (class ID) ataması yapar. İşleme sırasında kullanılmak üzere BI-RADS ontolojisi altındaki her sınıf için kelime listeleri eş anlamlıları ve kısaltmaları da içerecek şekilde hazırlanmıştır (Şekil 3.3).

3. Raporun bölümlere ayrılması:

Bu modül radyoloji raporunu, bulgular, izlenim, karşılaştırma gibi alt bölümlere ayırır (Şekil 3.4). Radyoloji raporları düz metin halinde olsa da, aslında yukarıda bahsedilen temel bölümler açısından basit ölçüde yapılandırılmıştır ve her bölüm kendisine ait bir başlığa sahiptir (örn: “History,” “Findings,” “Impression,” vb.). Bu modülde JAPE grameri kullanılarak öncelikle bölüm başlıkları işaretlenmiş ve bu başlıklardan sonra gelen metinler ilgili bölümler ile ilişkilendirilmiştir (Ek 2).

Başlığın olmadığı durumlar için de uzman görüşü ile bölümleri ayırt edebilmeyi sağlayan yapılar ek kurallar ile eklenmiştir. Örneğin, mamografi raporlarında bulgular bölümü her zaman meme yoğunluğunu tanımlayan bir cümle ile başlamaktadır, bu durumda meme yoğunluğunun geçtiği ilk cümle bulgular bölümünün ilk cümlesi olacaktır. Eğer bölüm başlığı yok ise, JAPE ile yazılmış kurallar kullanılarak öncelikle meme yoğunluğunun ilk geçtiği cümle aranacak ve bu cümle bulgular bölümünün başlangıcı olarak kabul edilecektir (Ek 2).



Şekil 3.4. Raporun bölümlere ayrılması işlemi sonucunun GATE NLP ortamındaki örnek ekran görüntüsü

Bu çalışmanın amacında belirtilen, karar destek sisteminde kullanılmak üzere çıkartılacak verilerin tamamı bulgular bölümünden elde edileceğinden, bu modülün esas odağı bulgular bölümüdür. Bölümler belirlendikten sonra her bölüm

içerisinde yer alan cümleler, isim tamlamaları ve fiil grupları bölümleri ile ilişkilendirilmişlerdir.

4. Mamografi gözlem bulgularının/lezyonların, bu bulguların özelliklerinin ve anatomik lokasyonların bulunması ve ilişkilendirilmesi:

Bu modül öncelikle bulgular bölümündeki tüm isim tamlamalarını tarar ve içerisinde bulunmak istenen varlıklara ilişkin BI-RADS terimlerini arar. Bulunan BI-RADS terimlerine göre, isim tamlamaları ya da sözcükler örnek 1 ve 2'de olduğu gibi isimlendirilmiş varlıklara dönüştürülür.

Örnek 1: Bir gözleme ve lokasyona ait ilişkilendirilmemiş çıkarım

[The breast tissue]_{Lokasyon} is [heterogeneously dense]_{Gözlem}

Örnek 2: Bir gözleme, lokasyona ve gözlem özelliklerine ait ilişkilendirilmemiş çıkarım,

There is [a 1 cm oval nodular density]_{Gözlem} with [an obscured margin]_{Gözlem_özelligi} in [the right breast]_{Lokasyon} in [the anterior depth]_{Lokasyon_özelligi}

Bu modül, farklı birçok kural içermekte olup (Çizelge 3.2) bu kuralların JAPE grameri ile yazılıp, metin üzerinde bu kuralların aranması yoluyla varlıklar özellikleri ile ilişkilendirilir.

Çizelge 3.2. Özelliklerle varlıkların ilişkilendirilmesini sağlayan kural örnekleri

Kurallar	Örnek Cümle	Varlıklar ve özellikleri
Kural 1: Tamlama (noun phrase) halinde bulunan herhangi bir lokasyon ya da gözlem terimi içerisinde yer alan tüm özellikler, içinde yer aldıkları gözlem ya da lokasyona aittirler.	There is [a 1 cm _{boyut} oval _{şekil} nodular density] _{Gözlem}	Bulgu: sınıf=kitle (mass), boyut=1 cm (değer=1, birim=cm), şekil=oval
Kural 2: Bir kavram ve özellik arasında sadece edat (örn: in, at, of, with vb.) ya da fiil grubu varsa, özellik kavrama eklenir ve özelliğe ait işaretleme kaldırılır.	There is [a 1 cm _{boyut} oval _{şekil} nodular density] _{Gözlem} with an [obscured margin] _{margin} _{Gözlem_özelligi} in [the right _{yön} breast] _{Lokasyon} in [the anterior depth] _{derinlik} _{Lokasyonun_özelligi}	Bulgu: sınıf=kitle (mass), boyut=1 cm (değer=1, birim=cm), şekil=oval, sınır=obscured Lokasyon: sınıf=breast, yön=right, derinlik=anterior
Kural 3: Kural 1 ve 2 uygulandıktan sonra, eğer bulgular bölümündeki bir cümle sadece bir varlık ve özellikler içeriyorsa, bu özellik ya da özellikler cümledeki tek varlığa aittir.	[The mass] _{Gözlem} in the central region of the left breast is [stable] _{Gözlem_özelligi}	Bulgu: sınıf=kitle (mass), değişkenlik=sabit

5. Varlıkların bağlamının (içeriğinin) tanımlanması; olumsuzluk ifade etme, hastaya ilişkin olup olmaması, zaman açısından değerlendirilmesi:

Klinik bulgular, bilgi çıkarımı için önemli olan olumsuzluk, kime ait olduğu (hastanın kendisine mi yakınına mı) ya da eski bir bulgu mu yoksa yeni mi olduğunu belirten özelliklere sahiptir. Bu özelliklerin saptanması için daha önceki çalışmalarda ConText ismi verilen bir algoritma geliştirilmiştir [67]. Bu algoritma, girdi olarak verilen bir varlığın ya da kavramın klinik durumunu, olumsuzluk/olumluluk (örn: “ruled out pneumonia”), kişinin kendisine ya da yakınına ait olma (örn: “family history of pneumonia”) ve geçmişte ya da şu anda görülmesi (“past history of pneumonia”) özelliklerini saptar [67]. ConText algoritması aynı zamanda GATE NLP sistemi içerisinde kullanılmak üzere bir işlem kaynağı olarak da geliştirilmiştir ve bu kaynak çalışmada geliştirilen ardışık düzen içerisine eklenmiştir.

6. Gözlem ve lokasyonlar arası ilişkinin çıkartılması:

Lokasyonların ve bulguların ilişkilendirilmesi için JAPE grameri kullanılarak Kalıp 1 ve 2'deki örneklerdeki gibi kalıpları anlayıp, bunlar içerisinde yer alan ilişkileri saptayan kurallar geliştirilmiştir (Çizelge 3.3). Lokasyon için varsayılan ilk atama “tanımlanmamış (not identified)” olarak yapılmıştır.

Kalıp 1: Bir tamlama içinde yer alan ve lokasyon bildiren her özellik bu tamlama içindeki gözlem bildiren varlıkla ilişkilidir.

Örnek 3:

[a [right]_{Lokasyon} breast enhancing focus tissue]_{Gözlem:sınıf=Mass,lokasyon=breast}
(yön=right)

Kalıp 2: Eğer lokasyon bilgisi gözleme ait varlıkla aynı tamlama içinde yer almıyorsa, gözlem bildiren varlığa ait tamlama etrafında en fazla dört bağlaç ya da bir fiil grubu arada olacak şekilde bulunan lokasyon kavramları, bu varlıklarla ilişkilendirilmiştir (Çizelge 3.3).

Çizelge 3.3. Lokasyon ve bulguların ilişkilendirilmesi için geliştirilen gramer örnekleri Bağlaç(B), Fiil grubu (FG), sıfır ya da bir (?)

Gramer	Örnek Cümle	Varlıklar ve özellikleri
{Lokasyon}	... <u>right breast</u> demonstrates	Gözlem: sınıf=breast_density,
{B}?{B}?{FG}	<u>fibroglandular tissue.</u>	lokasyon=breast: yön=right
?{B}?{B}?	In <u>the central right breast</u>	Gözlem: class=mass,
{Gözlem}	<u>approximately 3 o'clock</u> there is a <u>5mm oval mass.</u>	locatedIn=breast: laterality=right, saat_yönü =3 o'clock, bölge=central
{Gözlem}	There is a <u>right breast</u>	Gözlem: sınıf=mass,
{B}?{B}?{FG}	<u>enhancing focus in the 8</u>	lokasyon=breast: yön=right,
?{B}?{B}?	<u>o'clock position posteriorly.</u>	saat_yönü=8 o'clock,
{Lokasyon}		derinlik=central

7. Referans varlık çözümlemesi (Co-reference resolution):

Aynı bulgu farklı cümlelerde tekrar refere edilebilir ya da bir bulguya ait özellikler farklı cümlelere bölünmüş olarak verilebilir. Bu nedenle saptanan bulguların, aslında aynı bulguyla mı ilgili olduğu ya da birbirinden farklı mı olduğunu belirlemek önemlidir. Örneğin, aşağıdaki örnekte (Örnek 4), ‘this mass’ ve ‘5 mm oval mass’ aynı bulguya refere etmektedirler. Bir başka deyişle bu varlıklar birbirlerinin ortak referanslarıdır ve ortak referansların çözümlenebilmesi bilgi çıkarımı sistemleri için çok önemli bir rol oynamaktadır [68].

Örnek 4:

In the central right breast, 5 cm posterior to the nipple, there is [a 5 mm oval mass]_{Gözlem}. [This mass]_{Referans_gözlem} is well circumscribed.

Ortak referans çözümlemesi yapabilmek için, sadece bulgu varlıkları için çalışan basit bir çözümleme algoritması geliştirilmiştir. İlk olarak, zamir işlevi gören sözcükler işaretlendi (this, that, these and those), ve bu sözcüklerden herhangi birini içeren bulgu tamlamaları kendi özellikleri tutularak, bulgu_referansı olarak atanmıştır. Ardından en fazla üç cümlelik aralıklar içerilecek şekilde JAPE grameri ile kalıplar yazılarak, bulgular referans_bulguları ile eşleştirilip özellikleri toplanarak asıl referansa atanmıştır. Tanımlanan kalıplar aşağıda özetlenmiştir.

Kalıp 1: {Cümle içerir {Gözlem.sınıf=A} & {Referans.sınıf=A}}

Kalıp 2: {Cümle içerir {Gözlem.sınıf=A}}

{Cümle içerir {Referans.sınıf=A}}? (opsiyonel)

{Cümle içerir {Referans.sınıf=A}}

Özellikleri asıl gözlem varlığına klonlanan referans gözlemlere ait tüm işaretlemeler kaldırılarak, bu bulgular elenmiştir. Geliştirilen ortak referans çözümlemeleri bilgi çıkarımındaki gereksiz tekrarların engellenmesine yardımcı olur [69].

8. Rapordaki gözlemlerim benzersiz (tekil) olarak çıkarılması:

Bir raporda birden fazla lezyona ait gözlem yer alabilir ve bu gözlemlerin birbirleriyle olan farklılıkları belirlenerek, her bir bilgi çıkarımı gereksiz tekrara izin verilmeyecek şekilde yapılabilir. Bu durum için geliştirilen çözüm; bulguların yer aldığı lokasyonları temel almaktadır. Mamografi raporlarında belirtilen her bir lokasyonda sadece bir bulgu olacağından, eğer gözlemlerin sınıfına ek olarak lokasyonları da karşılaştırılırsa aynı gözlemden mi yoksa farklı gözlemden mi bahsedildiği saptanabilir. Gooch ve ark. [69] çalışmalarında bir kavram seti oluşturmuşlar ve bu setin alt kümelerini kavramların ontolojideki sınıflarına göre belirlemişlerdir. Geliştirdikleri algorithmada da her alt küme içerisinde yer alan kavramları rapordaki görülme sırasına göre taramış ve birbirini refere eden gözlemleri bulmayı amaçlamışlardır.

Benzer şekilde bu çalışmada geliştirilen algoritmada da rapordaki tüm gözlemler raporda görülme sırasına göre sıralanmış, ait oldukları sınıfa göre (BI-RADS ontolojisindeki tanımlamaları: mass, calcification, associated findings, other findings, special cases) alt kümelere ayrılmış ardından da ait oldukları sınıf döngüsü içinde ikili ikili karşılaştırılmışlardır. Önceki çalışmalardan farklı olarak, bu karşılaştırmada sınıf bilgisi ile birlikte, gözlemlerin bulunduğu lokasyon bilgileri de karşılaştırılarak gözlemlerin aynı ya da farklı olduklarının saptanması amaçlanmıştır. Örneğin, raporda rastlanan ilk sınıfı kitle (mass) olan gözlem ardından gelen tüm kitle gözlemleriyle tek tek lokasyonları açısından karşılaştırılmış, aynı lokasyonda olanların özellikleri klonlanmış ve referansa ait olan silinmiştir. Bu sürecin sonunda sistem, çıktı olarak sadece birbirinden farklı olan gözlemler elde etmiştir (Örnek 5).

Örnek 5:

[A right breast enhancing focus] in [the 8 o'clock position posteriorly] which measures [5 x 4 mm (AP x ML)]. In [the 12 o'clock position of the right breast at mid depth] there is [an oval 9 x 3 mm (AP x ML) mass].

Gözlemler

1. Gözlem: sınıf=kitle, boyut=5x4 mm
Lokasyon: yön=right, saat lokasyonu=8, derinlik=posterior
2. Gözlem: sınıf=kitle, boyut=9x3 mm
Lokasyon: yön=right, saat lokasyonu=12, derinlik=middle

Bazı raporlarda, iki gözleme ait lokasyonun tam olarak aynı olduğu durumlara örnekler de görülmüştür (Örnek 6), fakat bu gözlemlere ait ölçümler farklılık göstermektedir. Bu nedenle lokasyon bilgisine ek olarak gözlemlerin (eğer belirtilmiş ise) ölçümleri de karşılaştırılarak, aynı ya da farklı gözlemler olup olmadıklarına karar verilmiştir.

Örnek 6:

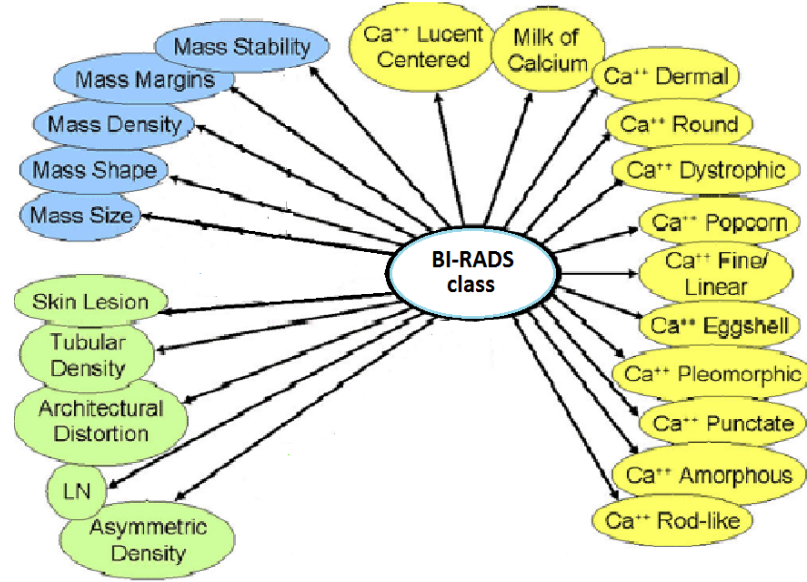
There is [a 2.5 cm round mass with a circumscribed margin] in [the right breast at 12 o'clock in the anterior depth]. There also is [a 1.5 cm oval mass with a circumscribed margin] in [the right breast at 12 o'clock in the anterior depth]. There is [a 1.8 cm round mass with a circumscribed margin] in the [left breast in the anterior depth central to the nipple]. Compared to previous films this mass is increased in size. There also is [a 1.4 cm oval mass with an obscured margin] in the [left breast in the anterior depth of the inferior region]. Compared to previous films this mass is increased in size.

Gözlemler

1. Gözlem: sınıf=Mass, boyut=2.5 cm, lokasyon= (yön=right, saat yönü = 12, derinlik= anterior)
2. Gözlem: sınıf =Mass, boyut =1.5 cm, lokasyon= (yön=right, clock face location = 12, derinlik=anterior)
3. Gözlem: sınıf =Mass, boyut =1.5 cm, lokasyon=(yön=left,derinlik=anterior, bölge=central), stability=increase.
4. Gözlem: sınıf =Mass, boyut =1.4 cm, lokasyon=(yön=left,derinlik=anterior, bölge=inferior), değişim=increase.

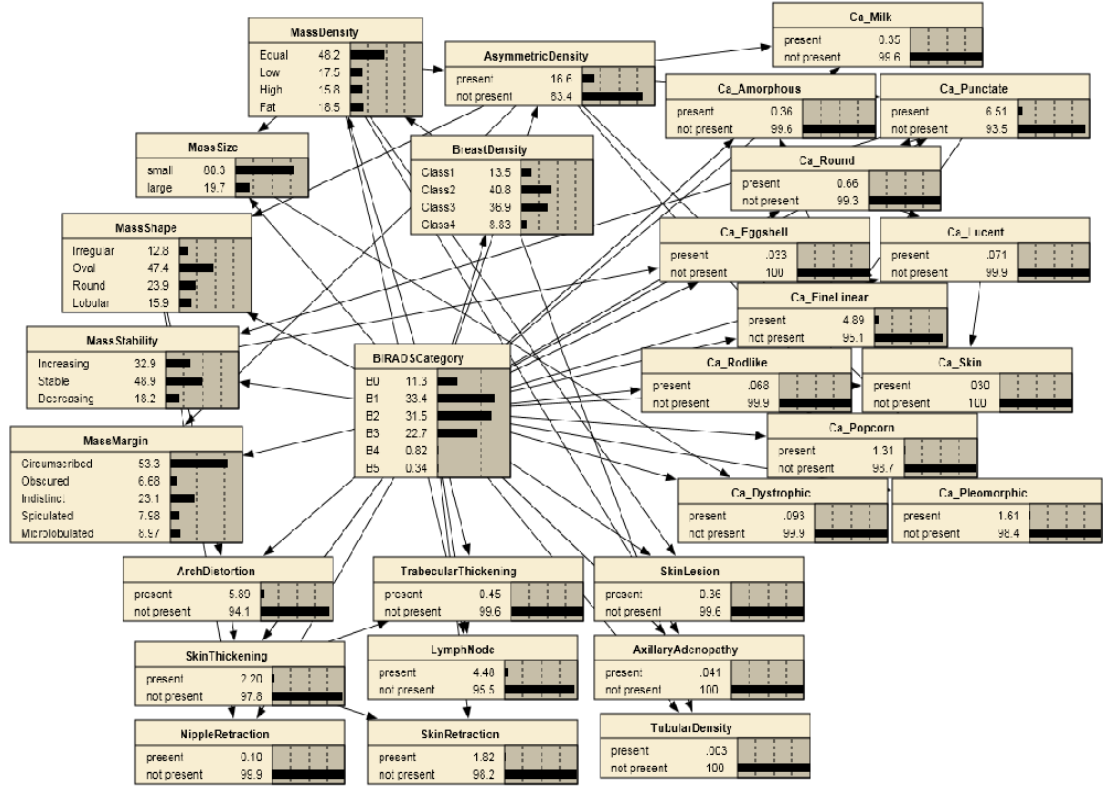
3.3. Bilgi Çıkarımı Sisteminin Karar Destek Sistemi ile Entegrasyonu

Bilgi çıkarımı ile entegre edilmek üzere Burnside ve arkadaşları tarafından Bayes ağları ile geliştirilen karar destek sistemi modifiye edilerek kullanılmıştır [35]. Burnside ve arkadaşları tarafından geliştirilen Bayes ağının modifiye edilmiş hali Şekil 3.5'de, bu ağın uygulamada kullanılan hali ise Şekil 3.6'de gösterilmiştir. Önceden geliştirilmiş bayes ağ modeli, BI-RADS tanımlayıcıları ile kişisel ve ailevi kanser öyküsünü kapsamakta olup bu çalışmada kullanılan bayes ağ modelinde hastanın hikayesine ait bilgiler raporların büyük bir kısmında rapor edilmemiş olduğundan kapsamamıştır [34]. Modelin modifiye edilmiş halinde ayrıca, lezyonu benin ve malin olarak iki kategoride sınıflandırmak yerine, bu model ile bir lezyona ait BI-RADS tanımlayıcıları girdi olarak verilerek sistem tarafından lezyona BI-RADS sonuç sınıflandırılma kodları atanmaktadır.



Şekil 3.5. Mamografi tanıları için geliştirilen Bayes Ağ Modeli (Modifiye edilmiş)

Ağın modifiye edilmesi aşamalarında Netica yazılımı kullanılmıştır [70] (Şekil 3.6). Bu çalışmada bilgi çıkarımı ve değerlendirme sürecinde kullanılan 500 raporun seçildiği PenRad (PenRad, Buffalo, MN) veri tabanında yer alan ve diğer aşamalarda kullanılan raporları içermeyen rapor seti (50200 lezyon içeren set) kullanılarak bayes ağının yapısı (düğümlerin birbirleriyle olan ilişkileri) bu veriden öğrenilmiş ve expectation maximization (EM) algoritması [71] kullanılarak model parametreleri hesaplanıp modelin son hali elde edilmiştir (Şekil 3.6).




Şekil 3.6. Bayes Ağ Modelinin Uygulamada Kullanımı

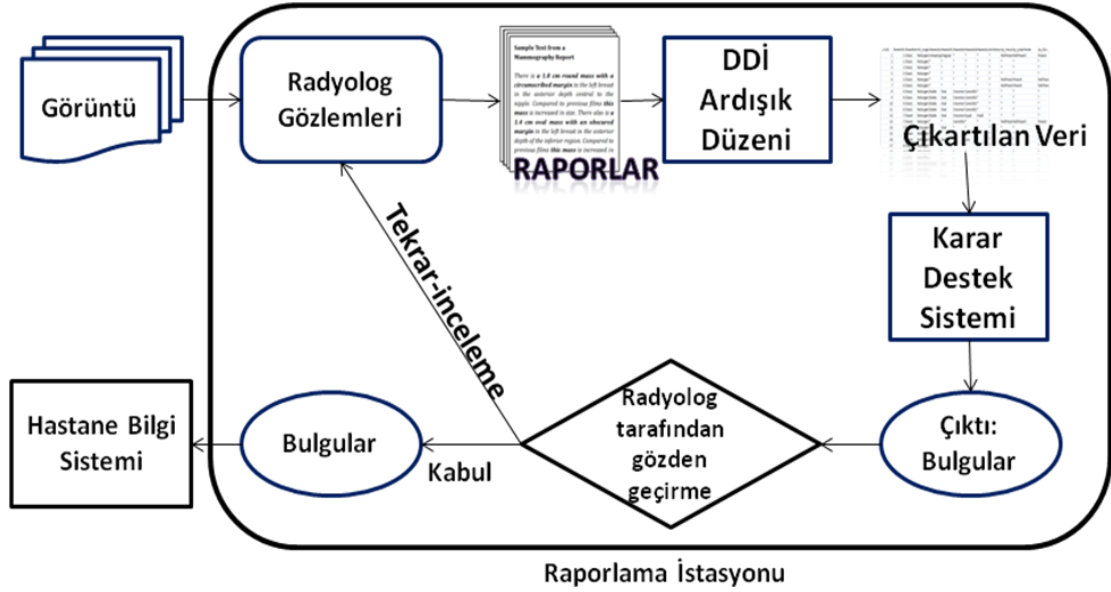
BI-RADS temelli ve Bayes ağları ile geliştirilmiş bu karar destek sistemi ile geliştirilen bilgi çıkarımı sistemi entegrasyonu, bilgi çıkarımı sisteminden elde edilen yapılandırılmış verilerin karar destek sistemine girdi olarak verilmesi yoluyla yapılmıştır. Bilgi çıkarımı sisteminden elde edilen bilgiler, XML ve Excel gibi formatlarda çıktı olarak sağlanabilmektedir (Ek 1).

Geliştirilen gerçek zamanlı karar destek sistemi serbest metin mamografi raporlarını girdi olarak alır, doğal dil işleme bileşeni ile bu raporlardan çıkartılan lezyonlara ait verileri bayes ağına girdi olarak verip, bu lezyonlar için uygun BI-RADS sınıflama kodlarını atamaktadır.

Önerilen sistem, bilgi çıkarımı sistemi ile karar destek sistemini birleştirerek gerçek zamanlı bir karar destek sistemi oluşturmakta ve bu sistem radyologlar raporları dikte ederken "gerçek zamanlı" olarak, yani rapor oluşturulurken lezyonlara ait son BI-RADS sınıflandırma kategorisini ve malin olma olasılıklarının hesaplanmasını amaçlamaktadır (Şekil 3.7 ve 3.8).



Şekil 3.7. Karar Destek Sistemi Akış Diyagramı



Şekil 3.8. Geliştirilen araçların iş akışı içerisinde gösterimi

3.4. Değerlendirme

3.4.1. Bilgi Çıkarımı Sisteminin Değerlendirilmesi

Bilgi çıkarımı sisteminin değerlendirilmesi için radyoloji veri tabanında elde edilen 300 rapor kullanılmıştır. Bu raporlara ait yapılandırılmış verilerin radyologlar tarafından kontrol ve revize edilmiş son hali ile geliştirilen sistemin çıktısı karşılaştırılarak, karşılaştırma sonucunda elde edilen bulgular ile bilgi çıkarım sisteminin performansını ölçmek amacıyla aşağıda tanımlanan başarı ölçütleri hesaplanmıştır.

Kesinlik (Precision): Sistem tarafından doğru sınıflandırılmış pozitif örnek sayısının toplam doğru pozitif örnek sayısına oranıdır.

$$\text{Kesinlik (K)} = \frac{\text{Gerçek Pozitif}}{\text{Gerçek Pozitif} + \text{Yanlış Pozitif}}$$

Hassasiyet (Recall): Sistem tarafından doğru sınıflandırılmış pozitif örnek sayısının, sistem tarafından pozitif olarak belirlenmiş tüm örnek sayısına oranıdır.

$$\text{Hassasiyet (H)} = \frac{\text{Gerçek Pozitif}}{\text{Gerçek Pozitif} + \text{Yanlış Negatif}}$$

F ölçütü (F measure): Kesinlik ve hassasiyet ölçütleri tek başına anlamlı bir karşılaştırma sonucu çıkarmamıza yeterli değildir. Her iki ölçütü beraber değerlendirmek daha doğru sonuçlar verir. Bunun için F ölçütü (F) tanımlanmıştır. F ölçütü, kesinlik (K) ve hassasiyetin (H) harmonik ortalamasıdır [72].

$$\mathbf{F\ ölçütü = 2KH/(K+H)}$$

Yukarıda tanımlanan ölçütler hem her bir gözlemin bulunmasındaki, hem de her gözleme ait özelliklerin tek tek bulunmasındaki başarıyı ölçmek için hesaplanmıştır. Bu hesaplamalar yapılırken, tam eşleşme (pozitif durum) olarak bilgi çıkarımı çerçevesindeki tüm bilgilerin doğruluğu, yarı eşleşme ise en az bir özelliğin eksik çıkarımı, yanlış eşleşme ise gözlemlere ait bilginin tamamen yanlış çıkartılması ya da hiç bulunamaması olarak tanımlanmıştır.

3.4.2. Sistemin Genellenabilirliğinin Değerlendirilmesi

Sistemin mamografi raporları dışında diğer raporlardan bilgi çıkarımı için kullanılabilirliğini değerlendirmek adına 30 raporluk (5 MR, 25 CT raporu) bir rapor seti ile pilot bir çalışma gerçekleştirilmiştir.

Raporlardaki anormal bulguları belirten lezyonlar ve bu lezyonların özellikleri bir uzman tarafından belirlenmiş olup, bu aşamada sadece, lezyonların kendisi, lokasyonu ve boyutu içerilmiştir.

Mamografi raporları için kullanılan BI-RADS sistemi diğer raporlar için yetersiz kalacağından terminoloji listesi RadLex yardımı ile genişletilmiştir. Fakat tüm RadLex terimlerini eklemek yerine sadece rapor setindeki raporlarda bahsi geçen terimler listeye dahil edilmiştir. Bu terimler, BI-RADS ve RadLex ontolojilerine benzer şekilde üç ana başlık altında toplanmıştır: Anatomik varlık (Anatomic Entity), Lokasyon ve Gözlem, ve her kategori için terim listeleri yaratılmıştır.

3.4.3. Karar Destek Sisteminin Çıktılarının Değerlendirilmesi

Karar destek sisteminin çıktılarının değerlendirilmesi amacıyla hem referans veri seti hem de otomatik olarak çıkartılan veriler karar destek sistemine ayrı ayrı girdi olarak verilerek, iki ayrı setteki gözlemler için uygun olacak BI-RADS sınıflandırma kodları bulunmuştur. İki veri seti için hesaplanan sınıflama kodlarının uyumu ise ağırlıklandırılmış Kappa (\hat{k}_w) kat sayısı ile değerlendirilmiştir.

Bu aşamada 166 lezyonun BI-RADS kategorisi referans veri setinde tanımlanmamış olduğundan bu gözlemler değerlendirmeye dahil edilmemiştir.

BULGULAR

4.1. Bilgi Çıkarımı Sistemi Bulguları

Referans setini oluşturan 300 rapor, toplam 797 farklı lezyon içermektedir. Bu raporlardan 102 tanesinde, metin içerisinde yapılan değişikliklerin tekrar veri tabanına aktarılması sırasında yaşanan aksilikler nedeniyle yapılandırılmış veri setinde oluşan uyumsuzluklar (birden fazla kez, eksik ya da tutarsız raporlama) uzman radyolog tarafından belirlenmiştir. Bilgi çıkarımı sisteminin değerlendirilme aşamasında uzman radyologlar tarafından kontrol ve revize edilen yapılandırılmış veri seti kullanılmıştır.

Geliştirilen bilgi çıkarımı sistemi, toplam 815 lezyon belirlemiş olup bunların 780'i gerçek pozitif, 35'i yanlış pozitif ve 17'si yanlış negatiftir. Burada yanlış negatif olarak isimlendirilen durum, referans veri setinde bulunan fakat sistem tarafından saptanamayan lezyonlara karşılık gelmektedir.

Saptanan lezyonlar arasında 57 tanesi yarı-eşleşme göstermektedir. Buna ek olarak, 12 kalsifikasyonun tipi doğru olarak saptanamamıştır ve sekiz tane meme yoğunluğu bilgisi kaçırılmıştır.

Sistemin genel değerlendirme sonucunu belirten ölçümlere göre, tüm lezyonların özellikleriyle birlikte saptanma doğruluğunu belirten kesinlik değeri 94.9 olup hassasiyet değeri 90.9'dir ve F ölçümü 92.8 olarak hesaplanmıştır. Çizelge 4.1'de değerlendirme sonuçları detaylı olarak verilmiştir.

Çizelge 4.1. Lezyonlara ait bilginin çıkarımının değerlendirilmesi sonuçları

Sonuçlar	Lezyonlar (özellikleri olmadan)	Lezyonlar (özellikleriyle)	Boyut	Değişim	Şekil	Sınır	Yoğunluk
Tam Eşleşme	780	723	184	452	232	165	104
Yarı Eşleşme	-	57	-				
Eşleşmeme	17 YN 35 YP	-	1 YP 5 YN	6 YP 18 YN	2YN	4 YN	1 YN
Kesinlik (%)	95.7	88.7	99.4	98.6	-	-	-
Hassasiyet (%)	97.8	90.7	97.3	96.1	99.1	97.6	99
Toplam (Altın standart seti)	797	797	190	476	234	169	105

YP= Yanlış pozitif YN= Yanlış negatif

4.2. Bilgi Çıkarımı Sisteminin Genellenabilirliği

30 raporluk pilot değerlendirme sonucunda, uzmanlar tarafından belirlenen 236 lezyonun 213'ü sistem tarafından saptanabilmiştir. Bu lezyonların 123 tanesi boyut bilgisine sahiptir fakat sistem sadece 76'sına ait boyut bilgisine ulaşabilmiştir. 16 tane ölçüm bilgisi kaçırılırken, 30 ölçüm yanlış saptanmıştır. 83 lezyon sistem tarafından saptanamazken, 23 lezyon yanlış pozitif olarak belirlenmiştir. Pilot değerlendirme sonucunda sistemin kesinliği 90,25 ve hassasiyeti 71,95 olarak hesaplanmıştır (Çizelge 4.2).

Çizelge 4.2. CT ve MR raporları için değerlendirme sonuçları

Lezyonlar	Negatif Tahmin	Pozitif Tahmin
Negatif	-	23
Pozitif	83	213
Toplam	83	236

4.3. Karar Destek Sistemi Sonuçlarının Karşılaştırılması

İki veri seti için BI-RADS sınıflama kodları arasındaki uyumu ölçmek için hesaplanan ağırlıklandırılmış Kappa (k_w) değeri $k_w=0.721$ 'dir ($p<0.01$). Bu değer iki veri seti arasında yüksek derecede uyum olduğunu göstermektedir.

Bu aşamada 166 lezyonun BI-RADS kategorisi altın standart veri setinde tanımlanmamış olduğundan bu lezyonlar değerlendirmeye dahil edilmemiştir. Test ve altın veri setlerindeki sınıflama kodlarına ait uyumsuzlukların çoğunluğu BI-RADS 2 ve BI-RADS 3 sınıflamaları arasında olmuştur. Referans veri setinde BI-RADS 3 olarak tanımlanan 12 lezyon test setinde BI-RADS 4 olarak tanımlanmıştır. 25 lezyon için de altın standart veri setinde BI-RADS 2 olarak tanımlanan bu lezyonlar test veri setinde BI-RADS 3 olarak belirlenmiştir. Ayrıca, 10 lezyon için sistem BI-RADS 3 kodunu atarken altın standart veri setinde bu lezyonlar BI-RADS 0 olarak tanımlanmışlardır.

Çizelge 4.3. Karar Destek Sistemi Değerlendirmesi sonuçları

Referans Sınıflaması	Sistem Sınıflaması						
	B0	B1	B2	B3	B4	B5	Toplam
B0	38	4	6	10	5	0	63
B1	13	80	11	5	0	0	109
B2	5	5	272	25	8	0	315
B3	2	3	4	89	12	0	110
B4	1	1	1	1	17	0	21
B5	0	0	0	0	0	13	13
Toplam	59	93	294	130	42	13	631

TARTIŞMA

Bu çalışma, mamografi karar destek sisteminde girdi olarak kullanılmak üzere metin halindeki raporlardan yapılandırılmış veri çıkartımı sağlayan bir sistemin geliştirilmesi ve bu verilerin karar destek sisteminde kullanımının değerlendirilmesi amacıyla gerçekleştirilmiş ve sonuçları aktarılmıştır. Mamografi sonuçlarındaki şüpheli bulgulara ait tahminleri hesaplayan Bayes ağları temelli karar destek sistemi gibi sistemlerin kullanılabilmesi için yapılandırılmış girdi verisi gereklidir [35-36]. Geliştirilen bilgi çıkarımı sisteminin kesinlik değeri 94.9 olup, hassasiyet değeri 90.9'dir ve F ölçümü 92.8 olarak hesaplanmıştır. Çalışmanın bulguları, yaklaşımımızın serbest metinlerden istenilen yapılandırılmış veriye ulaşmakta faydalı olabileceğini kanıtlamaktadır.

Mamografi raporlarından bilgi çıkarımı üzerine çok az sayıda çalışma yapılmıştır. Bu çalışmalar metin eşleştirme ve kural tabanlı yaklaşımlara dayanmaktadır [62, 73-77]. Önceki çalışmalar içerisinde, bu çalışmaya en yakın olan çalışma, 2009 yılında Nassif ve arkadaşları tarafından gerçekleştirilmiştir [75]. Fakat Nassif ve arkadaşlarının geliştirdiği sistem bir mamografi raporundaki bulguların, aynı gözleme mi yoksa farklı gözlemlere mi ait olduklarını ayırtılamamaktadır ve bu nedenle lezyon sayısı olduğundan daha fazla saptanmaktadır. Ayrıca, bu sistemde lezyon özellikleri ve lokasyonlar lezyonlarla ilişkilendirilmemektedir. Sistem temel olarak bir lezyonun bir raporda olup olmadığını var ise kaç kez belirtildiğini saptamakta ve çıktısını buna göre oluşturmaktadır. Bu çalışmada geliştirilen sistem ise birbirinden farklı lezyonları ayırtmakta ve aynı zamanda lezyonların özelliklerini ait oldukları bulgular ile eşleştirmektedir. Bunlara ek olarak, Nassif ve arkadaşlarının geliştirdikleri sistem bulgulara ait olumsuzluk eklerini saptamaktadır fakat bu çalışmada olduğu gibi bir bulgunun geçmişe mi şu ana mı ait olduğunu ya da hastanın kendisine mi yoksa hastanın aile bireylerinden birine mi ait olduğunu saptayamamaktadır. Ayrıca, Nassif ve arkadaşlarının sisteminde lezyonlara ait ölçüm değerleri saptanırken sadece en son belirtilen lezyona atama yapılabilmesi hatasına düşülmektedir. Sahip olduğu kısıtlılıklara ve bulgular ile özellikleri eşleştirememesine rağmen Nassif ve arkadaşlarının çalışması bulgular ve özelliklerin çıkartılmasında umut verici sonuçlar elde etmişlerdir [75].

Bu çalışmada mamografi raporlarında bulgulara ait bilgilerin çıkarımı için geliştirilen yaklaşım farklı bir çok açıdan tektir. Öncelikle, literatürde terimlere ait ilişkili kavramların bulunmasında 4-5 sözcüklük bir alanın kullanılması durumu yaygın iken [75], bu yaklaşımda cümleler ve isim ile fiil tamlamaları temel alınmıştır. Ayrıca, terimlere ait olumsuzluk, zaman ve özellikler bir arada saptandığından, bir bulguya ait bir çok ifadenin bir arada çıkartılabilmesi sağlanmaktadır. Bu özellik karar destek sistemleri için kritiktir, çünkü ancak bu

çıkarımları yapabilen sistemler karar destek sistemleri için girdi verisi sağlayabilirler. Ayrıca geliştirilen ve kullanılan kurallar sadece mamografi raporlarında değil tüm radyoloji raporlarında kullanılan gözlem, lokasyon, boyut (imaging observations, locations, size, vb.) gibi kavramlara odaklanmaktadır. Bu sayede, geliştiren kurallar ve sistemin farklı radyoloji raporları için de kullanımının mümkün olacağı düşünülmektedir.

Sistem BI-RADS ontolojisi temel alınarak geliştirilmiştir fakat, bu süreçte bir ontolojinin tüm bileşenlerinden yararlanılmamış, sadece sınıf hiyerarşisi kullanarak terimler bu hiyerarşi içerisindeki sınıf bilgileri ile eşleştirilmiştir. Terimlere ait sınıf kodu ve üst sınıf bilgisi eşleşen sözcüklere JAPE dili ile atanmıştır. Ontolojinin sağladığı tüm faydalardan yararlanılamasa da sistem ontoloji uyumlu geliştirildiği için ileride daha anlamlı bilgi çıkarımları yapabilmek için sistemin ontoloji bileşenin geliştirilmesi planlanmaktadır.

Radyoloji raporlarında bazı cümleler bulgu içermemekte olup, bu cümlelerin arındırılması bulguların saptanmasındaki performansı artırır. Bu amaçla, geliştirilen sistem öncelikle radyoloji raporlarını bölümlere ayırmakta ve bulgular bölümünde ilgili bilgileri aramaktadır. Ancak bulgular bölümünde de amaca yönelik olmayan cümlelerin ve terimlerin bulunması söz konusudur. İlgisiz saptamaların engellenmesi için, geliştirilen kurallar sadece görüntüye ait gözlem terimleri ile bu terimlerin geçmiş gözlemlere ait olmayanların ayrıştırılmasını sağlamaktadır.

Geliştirilen sistemin kaçırdığı ya da çıkarım sırasında hataya düştüğü durumlar da gözlenmiştir. Olumsuzluk ve geçmiş zamana ait bulguların saptanmasında ConText isimli bileşen kullanılmıştır. ConText olumsuzlukların saptanmasında 97% hassasiyet ve kesinlik, geçmiş bulguların saptanmasında ise 67.4%-82.5% hassasiyet, ve 74.2%-94.3% kesinlik sağlamaktadır [78]. ConText'in rapor edilmiş yüksek performansına rağmen, bu çalışmada bazı durumlarda yetersiz kaldığı saptanmıştır. Örneğin "*A coarse calcification noted in this region was removed,*" cümlesinde "was removed" kalıbı olumsuzluk olarak ConText veri tabanında bulunmadığından, "*The previously noted dense spiculated mass at the 8 o'clock position appears considerably less apparent being decreased in both density and size,*" cümlesinde kitle geçmişe ait olarak işaretlendiğinden sistem bu bulguları saptamada hataya düşmüştür. Ayrıca, sistem eski bulguların zaman içerisindeki değişimlerini izleme sağlamamaktadır, bu da yeni bulguların kaybına yol açmaktadır. Bu problemin eklenecek özel bir modülle çözümü sağlanabilir.

Geliştirilen sistemin bir başka kısıtlılığı ise kullanılan ifade kurallarının BI-RADS tanımlayıcılarını saptamak için geliştirilmiş olması ve radyolojide kullanılan diğer terminolojilerin içerilmemesidir. Bu durumun mamografi raporları içerisinde farklı terminolojilerin kullanılması durumunda kısıtlılık yaratabileceği düşünülse de, göz ardı edilmemesi gereken nokta BI-RADS terminolojisinin tüm mamografi raporlarında kullanılmasının önerilmesidir ve bu mamografi raporları için farklı bir terminoloji kullanılması olasılığının düşük olduğunu göstermektedir. Ayrıca geliştirilen sistem genişletilebilir olacak şekilde tasarlandığı için ontoloji modülü içerisine diğer terminolojiler de eklenerek terimlerin sistem tarafından atlanması engellenebilir. Sistem GATE NLP platformu kullanılarak ve alana özgü kurallar JAPE grameri ile yazılarak geliştirilmiş olup, tüm modül ve kurallar okunması kolay,

ulaşılabilir ve geliştirilebilir durumdadır. Bu nedenle gerekli eklemelerin kolaylıkla yapılabileceği düşünülmektedir.

Sistemin başka bir kısıtı da bir terim ve bu terimle ilgili özellikleri ararken üç cümlelik bir alanın kapsanması olup, bazı raporlarda bu alanın beş cümleye kadar çıktığının gözlenmesidir. Ayrıca, tasarlanan yapı sayı (count) ya da çoğulluk durumu (plurality) gibi birden çok lezyonun bulunduğu durumları tek lezyon gibi algılamaktadır. Bu nedenle "*several nodular densities*" ya da *two 8 mm intramammary lymph node were reported,*" gibi cümleler için sadece bir lezyona ait çıkarım yapılabilmektedir.

Bilgi çıkarımı sistemi kural tabanlı yöntemlerle geliştirilmiştir. Benzer bir sistemin istatistiksel yöntemler kullanılarak da geliştirilmesi mümkündür. Literatürde bazı kural tabanlı sistemlerin istatistiksel makine öğrenmesine dayalı sistemlere dönüştürülmesine dair çalışmalar bulunmaktadır [65, 79]. Her iki yaklaşım da avantaj ve dezavantajlar barındırmaktadır [62, 79-81]. Kural tabanlı yaklaşımlar tahminin ve yorumunun daha kolay olması açısından daha komplike ve gürültülü çıktılar veren istatistiksel yöntemlere göre avantajlıdırlar. Genel olarak, kural tabanlı sistemler, uzmanın dahil olmasının hem mümkün hem de gerekli olduğu daha spesifik-dar (narrow) alanlarda daha faydalıdırlar [82]. Benzer şekilde mamografi alanı da hem daha dar hem de uzman desteğinin sağlanabildiği bir alan olduğundan kural tabanlı yaklaşım kullanılmıştır. İleride kural tabanlı ve istatistiksel yöntemlerin bir arada kullanılması ise şüphesiz daha iyi ve genellenilebilir sonuçlar sağlayacaktır.

Bilgi çıkarım sistemlerinin geliştirilmesi ve değerlendirilebilmeleri için geniş, güvenilir ve yapılandırılmış referans radyoloji rapor setlerine ihtiyaç duyulmakta olup, radyoloji raporlarının yapılandırılmamış doğası, bu raporları okuyup elle yapılandırılmış veri setlerinin oluşturulmasının zaman ve emek gerekliliği nedeniyle zorluk söz konusudur. Bu gibi zorluklar nedeniyle bu çalışmada kullanılacak referans (altın standart) rapor setinin radyologlar tarafından yapılandırılmış ve raporlama uygulamasına kayıt edilmiş raporlardan oluşturulmasına karar verilmiştir. Bu uygulamada radyologlar iş akışları içerisinde hem veri girişi yaparak rapor oluşturmakta, hem de serbest metin halinde raporlar oluşturulmakta olup bu uygulama sayesinde binlerce rapordan oluşan bir rapor seti oluşturulmuştur. Fakat bu durum, oluşturulan serbest metin raporların kullanılan uygulamanın etkisiyle normalde karşılaşılabilecek değişkenlikte olmaması ve bu durumun çalışma sonuçlarının normal şartlardaki durumdan çok daha iyi çıkması yanlıgısını doğurmak gibi kısıtlılıklar içermektedir. Aynı zamanda radyologlar sistem tarafından üretilen raporu okuyup düzeltmeler yaptıklarından kaybedilen değişkenlik göreceli olarak yeniden sağlandığından raporların benzerliği engellenmektedir.

Radyoloji raporlarının alındığı sistemin bir başka kısıtı olarak, radyologlar son oluşturulan serbest metinlerde düzeltme yaparken uygulamanın fonksiyonel bir özelliği olarak bu düzeltmeleri yapılandırılmış veri girişi sonuçlarına uygulamadıklarından referans veri setinde tutarsızlıklar gözlenmektedir. Bu kısıtı ortadan kaldırmak için serbest metinler ve referans veri seti karşılaştırılarak tutarsızlıklar saptanmış ve uzman görüşüne başvurularak referans veri seti revize edilmiştir. İki uzman radyolog 300 raporu inceleyerek referans rapor ve veri setinin son halini oluşturmuşlardır. Değerlendirme için daha fazla rapor kullanılması

istenilen bir durum olsa da geliştirilen sistemin ilk değerlendirmesi için elde edilen rapor setinin yeterli olacağı düşünülmüştür. Fakat gelecek çalışmalarda daha geniş, değişken ve mümkünse bir raporlama sistemi tarafından üretilmeyen raporların kullanılması uygun olacaktır.

Rapor setiyle ilgili bir başka kısıt da, örnek alınan rapor setinin tek bir kuruma ait olması ve rapor bölümlerinin ve ifadelerinin kurumlar arası yüksek ölçüde değişim gösterme ihtimalidir. Örneğin bölüm başlıklarının atlandığı stiller olabilir. Bulgulara ait bölüm başlığının bulunmadığı durumlar için ilk cümlenin meme yoğunluğu bulgusuyla başlaması üzerine geliştirilmiş bir kuralla, belirtilen kısıta çözüm sağlanmaya çalışılmıştır fakat, bu kural her durumda çözüm olmayabilir. Yine de sistem geliştirilebilir olarak tasarlandığından, farklı tipte raporların bulunduğu durumlar için gerekli modifikasyonlar sağlanabilir.

Bilgi Çıkarımı Sisteminin Genellenebilirliği

Yapılan pilot değerlendirmenin sonuçları sistemin performansının yüksek olduğunu gösterse de (kesinlik 90,25 ve hassasiyet 71,95), rapor setinin oldukça az sayıda rapor içerdiği ve yine de bir çok potansiyel sorunun gözlemlendiği unutulmamalıdır. Örneğin, lenf nodu bir lokasyon iken, lenf nodundaki değişim bulgu niteliğindedir ve bu bulgu mamografi raporlarında çıkartılmadığından, sadece lenf nodunun varlığı ya da yokluğu saptandığından, sistem lenf nodu ile ilgili bulguları kaçırmaktadır.

Mamografi raporlarından farklı olarak, CT raporlarında segment bilgisi yer almaktadır ve lokasyon yerine kullanıldığı durumlar söz konusudur (örn: Segment 3 (16/67) measuring 10 mm, previously 6 mm). Segment bilgisi lokasyon sınıfının altında tanımlanmadığından, sadece segmentlere göre tanımlanmış bulgular kaçırılmaktadır.

Pilot değerlendirme sonuçlarını olumsuz etkileyen diğer faktörler, sistemin önceki bölümde belirtilen genel problemleri ile ilgilidir. Sistemin genellenilebilirliğinin değerlendirilmesi için bu pilot çalışma detaylı şekilde genişletilmeli ve daha fazla sayıda rapor kullanılmalıdır.

Karar Destek Sistemi ile Entegrasyon

Çalışmanın karar destek sistemi bölümünde amaç bilgi çıkarımı sistemi ile çıkartılan BI-RADS ontolojisi temel alınarak yapılandırılmış verinin daha önceden geliştirilmiş bir karar destek sistemine girdi olarak verilerek, karar destek sisteminin çıktılarının değerlendirilmesidir. Buna ek olarak, hekimlerin iş akışına kolay entegre olabilmesi ve ek bir maliyet ya da zaman gerektiren işlem olmadan bir karar desteğin direkt olarak serbest metin raporlardan sağlanabilirliği gösterilmek istenmiştir. Fakat bir çok bilgi çıkarımı sisteminin olduğu gibi geliştirilen sistemin de bir önceki bölümde rapor edilen kısıtlılıkları mevcuttur, bunların yanı sıra bilgi çıkarımı sisteminin ürettiği yapılandırılmış verinin karar destek (girdi olarak verilen her bir lezyon için kanser olasılığı tahmini ve her bir bulgu için BIRADS son sınıflama

kodunun atanması) sağlamadaki etkinliği de bu veri seti ve referans veri seti ile üretilen olasılık değerleri ve BI-RADS sınıf kodları karşılaştırılarak araştırılmıştır. Yapılan literatür taramasına göre bu çalışma bu tür bir karşılaştırmanın yapıldığı ilk çalışmadır, ayrıca tüm sistemin klinik yararlılığını direkt olarak yansıtması açısından önemlidir.

Değerlendirme çalışmasının sonucunda, gerçek zamanlı karar destek uygulamasının referans veri seti ve bilgi çıkarımı sisteminin ürettiği veri setinden elde ettiği iki ayrı sonuç çıktısının uyumlu olduğu görülmüştür ve atanan BI-RADS sınıfları için uyum istatistiği $\kappa_w=0.721$ olarak hesaplanmıştır ($p<0.01$).

Serbest metin radyoloji raporları karar destek sistemlerinin (Bayes ağılarıyla oluşturulmuş karar destek sistemi ve diğer bilgisayar tabanlı destek sistemleri gibi) gerektirdiği yapılandırılmış ve kontrollü bir terminolojik dil [83] yapısında olmadıklarından, yapılandırılmamış metin ile yapılandırılmış veri arasındaki boşluğu doldurmak için doğal dil işleme yöntemlerinin kullanımı ilgilenilen bir konudur [51]. Medikal metinlerde bahsi geçen kavramları otomatik olarak saptayıp çıkartmak için DDİ yöntemlerinin kullanıldığı bir çok çalışma bulunmaktadır [84-91]. Bu çalışmaların bazılarında DDİ sistemi ile KDS aktif veya pasif olarak entegre edilmeye çalışılmıştır [51, 79, 92-93].

Bu çalışmalar içinde, geliştirilen sisteme en yakın olan MedLEE özellikle radyoloji alanındaki KDS uygulamaları için geliştirilmiş semantik bir DDİ sistemidir [74, 94]. MedLEE, derin bir gramatik alt yapıya sahip, geliştirilebilir terminolojileri içeren ve teorik olarak mamografi için kullanılacak bir karar destek sistemi için gerekli verileri sağlayabileceği düşünülen bir sistemdir. Mamografi alanında bir uygulama çalışması da mevcuttur [94]. Fakat MedLee'nin tasarımında BI-RADS ya da hastaya ait gerekli kanser hikayesine dair bilgiler içerilmemiştir [74]. Ayrıca, sistem açık kaynak kodlu olmayıp, ekleme ya da modifikasyon yapma izni herkese açık değildir.

BI-RADS sınıflama sistemini bilgi kaynağı olarak kullanan farklı sistemler bulunmaktadır [63-64, 77, 95-97], fakat bu sistemler her bir lezyonu tek tek saptayıp özellikleri ile ilişkilendirme gibi daha üst düzey bilgi çıkarımı sağlamamaktadırlar [63-64, 97]. Bu sistemlerin hedeflerinden biri karar destek sistemlerinde kullanılmak üzere bilgi çıkarımı sağlamak olmasına rağmen, karar destek sistemleriyle çıkartılan bilginin kullanılmasının değerlendirilmesi üzerine herhangi bir çalışma bulunmamaktadır. **Yapılan literatür taramasının ışığında, bu çalışma bilgi çıkarımı sistemi ile sağlanan bilgilerin bir karar destek sisteminde girdi verisi olarak kullanıldığında elde edilen sonuçların değerlendirildiği ilk çalışmadır.** Bu çalışmanın, iş akışı içerisinde otomatik veri girdisiyle karar destek sisteminin kullanılmasına yönelik çalışmalara katkı sağlayacağı düşünülmektedir.

Yapılandırılmamış klinik metinlerin karar destek sistemleriyle doğal dil işleme yöntemleri kullanılarak entegrasyonu daha önce tanımlanan bir kavramdır [92-93, 98]. Fusharman ve arkadaşları derleme çalışmalarında DDİ-KDS sistemlerini ayrı bir kategoride toplamaktadırlar. Bu kategori, sadece spesifik bir amaç için geliştirilen sistemleri, KDS tarafından kullanılan DDİ modüllerini ve tek başına metinleri alıp KDS'i için girdi verisi üreten sistemleri içermektedir [8]. Bu

derlemedeki tanımlar ışığında, bu çalışmada geliştirilen sistemin, spesifik bir alan için (mamografi) belirli bir çıktıya ulaşma amacıyla (Bayes ağ modelindeki düğümler), tek başına (stand-alone) metinleri alıp KDS'i için girdi verisi üreten, geliştirilmeye ve modifikasyona açık bir sistem olarak tanımlamak mümkündür.

Fusharman ve ark. derlemelerinde ayrıca DDİ sistemlerinin klinik metinlerin gerçek zamanlı olarak işlenerek iş akışı içerisinde karar destek için bir girdi verisi olarak kullanılabilmesini de gündeme getirmişlerdir [8]. Bu çalışma özellikle bu amaca hizmet eden bir senaryoya odaklanmış olup, geliştirilmiş sistem ile KDS entegrasyonun iş akışı içerisinde kullanıldığında mamografi raporu tamamlandığı anda radyoloğa gözlemediği lezyonlarla ilgili malin olma olasılığı ya da en olası BI-RADS son sınıf ataması sağlayabilecektir.

DDİ-KDS entegrasyonunun daha önce de rapor edilen önemli problemlerinden biri, DDİ tarafından çıkartılan bilginin direkt olarak KDS'ine verilememesi ve ekstra işlem gerektirmesidir [37]. Bu çalışmada geliştirilen sistemin en büyük avantajlarından biri bilgi çıkarımı sisteminin karar destek sisteminin bilgi ihtiyacına göre bilgi çıkarımı sağlaması ve bu sayede herhangi bir ek işlem gerektirmemesidir, yani DDİ sisteminin ürettiği veri KDS'de direkt olarak kullanılabilir.

Çalışmanın DDİ-KDS entegrasyonu kısmı da bazı sınırlılıklar içermektedir. Çalışmada kullanılan rapor seti tek bir enstitüden alınmıştır, farklı birimlerden alınan raporlar farklılıklar gösterebilir. Bu nedenle sistemin çok merkezli olarak değerlendirilmesi gereklidir. Fakat temelde mamografide kullanılan jargon benzer olduğundan sistemin kolayca farklı merkezlerden gelen raporlar için uygun hale getirilebileceği düşünülmektedir. Ayrıca, hem farklı merkezlerden gelen hem de daha büyük sayıda rapor içeren rapor setleri üzerinde değerlendirilmeler yapılması sistemin rapor edilen kesinlik ve hassasiyetini doğrulamak açısından faydalı olacaktır.

Sistemin bir başka kısıtı da çok az raporda bahsedilmesi nedeniyle yaş, kanser öyküsü ve hormon tedavisine dair bilgilerin çıkartılmamasıdır. Oysa ki meme kanseri risk tahmin modellerinde mamografik bulgulara ek olarak hastaya ait diğer risk faktörlerinin de kullanılmasının tahmin doğruluğunu arttırdığı bilinmektedir [35]. Gerektiğinde bu çıkarımlar için gerekli kural ve gramer yapılarının eklenmesiyle çıkarım sağlanabilir. Ayrıca, sistem genişletilerek eksik bilgiler radyologlara gözlemleri sırasında hatırlatılabilir.

Elbette ki, DDİ-KDS'nin performansı, işlenen metnin kalitesi ile kısıtlıdır. Serbest metindeki bilgiler tutarsız ve eksik olabilir [37]. Buna örnek olarak bu çalışmada karşılaşılan problemler verilebilir. Örneğin, 300 rapordan 138 tanesinde kişinin ya da akrabalarının kanser öykülerine ait bilgi bulunmamaktadır. Ayrıca, çok az sayıda raporda yaş ve hormon tedavisi bilgisine rastlanmıştır. Geliştirilen DDİ işleme sistemine gerekli eklemeler yapılarak, raporlardaki eksik ya da tutarsız bilgilerin de saptanarak, radyologlara rapor oluşturulma aşamasında geri bildirim sağlanması da amaçlanmaktadır. Fakat, bu çalışmalar henüz başlangıç seviyesindedir [99].

Çalışmanın son kısıtı, sistemin son çıktısının gerçek referans olan biyopsi sonuçlarıyla karşılaştırılmamasıdır. Öte yandan, gerçek referans olan biyopsi sonucu ile karşılaştırmanın da yapılması, sistemin etkinliği konusunda daha hassas bilgi verecektir. Yine de bu çalışmada anlatılan sistemin radyologların iş süreçlerinde hem klinik hem de pratik fayda sağlayacağı düşünülmektedir. Dolayısı ile, bu sistemin gerçek klinik faydasının ileriki çalışmalarda detaylı incelenmesi gerekmektedir.

Ticari radyoloji raporlama uygulamaları konuşmadan metine aktarım sağlamakta olup, radyologlar dikte ederken metin halindeki raporu oluşturup göstermektedirler. Bazı uygulama sağlayıcıları bu çalışma gibi çalışmaların uygulamaya geçmesi için gereken ve metin halindeki raporu alıp KDS'nin ürettiği sonuçları radyologun ekranına göndermeyi sağlayacak entegrasyon ara yüzlerini de sunmaktadırlar. Bu gibi ara yüzlerin geliştirilen uygulama ile kullanılabilirliği ileriki çalışmalarda incelenmelidir.

SONUÇLAR

Yapılandırılmamış metin halindeki mamografi raporları içerisinde önemli miktarda veri barındırmaktadır ve bulgulara ait bu verilerin yapılandırılmış olarak çıkartılması karar desteği için katkı sağlayabilir. Bu amaçla bu çalışmada, mamografi raporlarından karar destek için gerekli olan bilginin otomatik çıkarımını sağlayan kural tabanlı bir bilgi çıkarımı sistemi geliştirilmiş, çıkartılan veri doğrudan karar destek sistemine verilerek sonuçları değerlendirilmiştir.

Bu çalışmanın bilgi çıkarımı bölümünün temel katkılarından biri, bir çok lezyon bulgusunun yer aldığı durumlarda, her bir lezyon ve bu lezyonun özellikleri için ayrı bir bilgi çıkarımı yapılmasıdır. Bu sayede karar destek uygulamaları ya da diğer uygulamalar için gerekli olan yapılandırılmış verinin serbest metin halinde bulunan raporlardan sağlanabilmesi konusunda katkı sağlanıldığı düşünülmektedir.

Çalışmanın ikinci kısmında ise, karar destek sistemlerinin klinisyenlerin iş akışına kolayca entegre olabilmelerini sağlamak amacıyla, bilgi çıkarımı sisteminin sağladığı veriyi analiz eden bir gerçek zamanlı karar destek sistemi geliştirilmiş ve değerlendirilmiştir. Değerlendirme sonuçları, geliştirilen sistemin sağladığı veri ve referans veri girdisi ile elde edilen karar destek sistemi sonuçlarının tutarlı olduğunu göstermiştir. **Çalışmanın bu bölümünün en önemli katkısı, bilgi çıkarımı sistemi tarafından üretilen verinin doğrudan (başka bir ek işlem görmeden) karar destek sistemine verilip sonuçlarının değerlendirildiği bir ilk çalışma olmasıdır.**

Özetle, geliştirilen sistem yapılandırılmış ve tutarlı girdilerle çalışıp, yine yapılandırılmış, tutarlı ve olasılıklarla desteklenen sonuçlar ürettiğinden bu sistemin kullanımının mamografi karar sürecindeki değişkenliği azaltması, radyologlar arası iletişimi güçlendirmesi ve uygulamaların kalitesini artırması beklenmektedir.

KAYNAKLAR

1. Saslow D, Boetes C, Burke W, Harms S, Leach MO, Lehman CD, et al. American Cancer Society guidelines for breast screening with MRI as an adjunct to mammography. *CA Cancer J Clin.* 2007 Mar-Apr;57(2):75-89.
2. Humphrey LL, Helfand M, Chan BK, Woolf SH. Breast cancer screening: a summary of the evidence for the U.S. Preventive Services Task Force. *Ann Intern Med.* 2002 Sep 3;137(5 Part 1):347-60.
3. Fletcher SW, Elmore JG. Clinical practice. Mammographic screening for breast cancer. *N Engl J Med.* 2003 Apr 24;348(17):1672-80.
4. Smith RA, Cokkinides V, Eyre HJ. American Cancer Society guidelines for the early detection of cancer, 2006. *CA Cancer J Clin.* 2006 Jan-Feb;56(1):11-25; quiz 49-50.
5. Baum JK, Hanna LG, Acharyya S, Mahoney MC, Conant EF, Bassett LW, et al. Use of BI-RADS 3-probably benign category in the American College of Radiology Imaging Network Digital Mammographic Imaging Screening Trial. *Radiology.* 2011 Jul;260(1):61-7.
6. Alpert HR, Hillman BJ. Quality and variability in diagnostic radiology. *J Am Coll Radiol.* 2004 Feb;1(2):127-32.
7. Berg WA, Campassi C, Langenberg P, Sexton MJ. Breast Imaging Reporting and Data System: inter- and intraobserver variability in feature analysis and final assessment. *AJR Am J Roentgenol.* 2000 Jun;174(6):1769-77.
8. Baker JA, Kornguth PJ, Floyd CE, Jr. Breast imaging reporting and data system standardized mammography lexicon: observer variability in lesion description. *AJR Am J Roentgenol.* 1996 Apr;166(4):773-8.
9. Smith-Bindman R, Chu P, Miglioretti DL, Quale C, Rosenberg RD, Cutter G, et al. Physician predictors of mammographic accuracy. *J Natl Cancer Inst.* 2005 Mar 2;97(5):358-67.
10. Kerlikowske K, Grady D, Barclay J, Frankel SD, Ominsky SH, Sickles EA, et al. Variability and accuracy in mammographic interpretation using the American College of Radiology Breast Imaging Reporting and Data System. *J Natl Cancer Inst.* 1998 Dec 2;90(23):1801-9.

11. Lee HJ, Kim EK, Kim MJ, Youk JH, Lee JY, Kang DR, et al. Observer variability of Breast Imaging Reporting and Data System (BI-RADS) for breast ultrasound. *Eur J Radiol.* 2008 Feb;65(2):293-8.
12. Lai XJ, Zhu QL, Jiang YX, Dai Q, Xia Y, Liu H, et al. Inter-observer variability in Breast Imaging Reporting and Data System (BI-RADS) ultrasound final assessments. *Eur J Radiol.* 2011 Jun 6.
13. Lazarus E, Mainiero MB, Schepps B, Koelliker SL, Livingston LS. BI-RADS lexicon for US and mammography: interobserver variability and positive predictive value. *Radiology.* 2006 May;239(2):385-91.
14. Siegel R, Ward E, Brawley O, Jemal A. Cancer statistics, 2011: The impact of eliminating socioeconomic and racial disparities on premature cancer deaths. *CA Cancer J Clin.* 2011 Jul-Aug;61(4):212-36.
15. Jemal A, Siegel R, Xu J, Ward E. Cancer statistics, 2010. *CA Cancer J Clin.* 2010 Sep-Oct;60(5):277-300.
16. DeSantis C, Siegel R, Bandi P, Jemal A. Breast cancer statistics, 2011. *CA Cancer J Clin.* 2011 Nov-Dec;61(6):409-18.
17. Ramirez-Torres N, Robles-Robles AG, Villafana-Vazquez VH, Hernandez-Valencia M. [Breast cancer and subsequent pregnancy. Infertility, death risk and survival]. *Ginecol Obstet Mex.* 2010 Feb;78(2):85-93.
18. Schonberg MA, Marcantonio ER, Ngo L, Li D, Silliman RA, McCarthy EP. Causes of death and relative survival of older women after a breast cancer diagnosis. *J Clin Oncol.* 2011 Apr 20;29(12):1570-7.
19. Riihimaki M, Thomsen H, Brandt A, Sundquist J, Hemminki K. Death causes in breast cancer patients. *Ann Oncol.* 2011 May 17.
20. Bakanlık TCS. Resmi web sitesi Sağlık İstatistik Yıllıkları
21. V. Ö. BREAST CANCER IN THE WORLD AND TURKEY. *The Journal of Breast Health.* 2008;4(2):7-11.
22. Burnside ES, Sickles EA, Bassett LW, Rubin DL, Lee CH, Ikeda DM, et al. The ACR BI-RADS experience: learning from history. *J Am Coll Radiol.* 2009 Dec;6(12):851-60.
23. Liberman L, Abramson AF, Squires FB, Glassman JR, Morris EA, Dershaw DD. The breast imaging reporting and data system: positive predictive value of mammographic features and final assessment categories. *AJR Am J Roentgenol.* 1998 Jul;171(1):35-40.
24. Liberman L, Menell JH. Breast imaging reporting and data system (BI-RADS). *Radiol Clin North Am.* 2002 May;40(3):409-30, v.

25. Park CS, Lee JH, Yim HW, Kang BJ, Kim HS, Jung JI, et al. Observer agreement using the ACR Breast Imaging Reporting and Data System (BI-RADS)-ultrasound, First Edition (2003). *Korean J Radiol.* 2007 Sep-Oct;8(5):397-402.
26. Monticciolo DL, Caplan LS. The American College of Radiology's BI-RADS 3 Classification in a Nationwide Screening Program: current assessment and comparison with earlier use. *Breast J.* 2004 Mar-Apr;10(2):106-10.
27. Taplin SH, Ichikawa LE, Kerlikowske K, Ernster VL, Rosenberg RD, Yankaskas BC, et al. Concordance of breast imaging reporting and data system assessments and management recommendations in screening mammography. *Radiology.* 2002 Feb;222(2):529-35.
28. D'Orsi CJ, Getty DJ, Swets JA, Pickett RM, Seltzer SE, McNeil BJ. Reading and decision aids for improved accuracy and standardization of mammographic diagnosis. *Radiology.* 1992 Sep;184(3):619-22.
29. Baker JA, Kornguth PJ, Lo JY, Williford ME, Floyd CE, Jr. Breast cancer: prediction with artificial neural network based on BI-RADS standardized lexicon. *Radiology.* 1995 Sep;196(3):817-22.
30. Colombet I, Dart T, Leneveut L, Zunino S, Menard J, Chatellier G. Combining risks estimations and clinical practice guidelines in a computer decision aid: a pilot study of the EsPeR system. *Stud Health Technol Inform.* 2003;95:525-30.
31. Hopkins UTSMCaDaTBGaJ. CancerGene with BRCAPRO, MMRpro, PancPRO, and MelaPRO. ©2004 UTSW MEDICAL CENTER Available from: <http://www4.utsouthwestern.edu/breasthealth/cagene/default.asp>.
32. Cuzick J. IBIS Breast Cancer Risk Evaluation Tool. Cancer Research UK Centre of Epidemiology, Mathematics and Statistics, Wolfson Institute of Preventive Medicine, Charterhouse Square, London 2008; Available from: <http://www.ems-trials.org/riskevaluator/>.
33. Krohn R. JHIM quick study: healthcare business intelligence and real-time decision support systems. *J Healthc Inf Manag.* 2004 Summer;18(3):14-6.
34. Burnside E, Rubin D, Shachter R. A Bayesian network for mammography. *Proc AMIA Symp.* 2000:106-10.
35. Burnside ES, Davis J, Chhatwal J, Alagoz O, Lindstrom MJ, Geller BM, et al. Probabilistic computer model developed from clinical data in national mammography database format to classify mammographic findings. *Radiology.* 2009 Jun;251(3):663-72.
36. Burnside ES, Rubin DL, Fine JP, Shachter RD, Sisney GA, Leung WK. Bayesian network to predict breast cancer risk of mammographic microcalcifications and reduce number of benign biopsy results: initial experience. *Radiology.* 2006 Sep;240(3):666-73.

37. Burnside ES, Rubin DL, Shachter RD. Using a Bayesian network to predict the probability and type of breast cancer represented by microcalcifications on mammography. *Stud Health Technol Inform.* 2004;107(Pt 1):13-7.
38. Bonis J, Sancho JJ, Sanz F. [Computer-assisted clinical decision support systems]. *Med Clin (Barc).* 2004;122 Suppl 1:39-44.
39. Bright TJ, Wong A, Dhurjati R, Bristow E, Bastian L, Coeytaux RR, et al. Effect of clinical decision-support systems: a systematic review. *Ann Intern Med.* 2012 Jul 3;157(1):29-43.
40. Euhus DM. Understanding mathematical models for breast cancer risk assessment and counseling. *Breast J.* 2001 Jul-Aug;7(4):224-32.
41. Hu Z, Li X, Feng MH, Chu JJ, Xie W. [Models for risk assessment and prediction in breast cancer]. *Zhonghua Liu Xing Bing Xue Za Zhi.* 2009 Oct;30(10):1073-7.
42. Antoniou AC, Pharoah PP, Smith P, Easton DF. The BOADICEA model of genetic susceptibility to breast and ovarian cancer. *Br J Cancer.* 2004 Oct 18;91(8):1580-90.
43. Pauw AD, Stoppa-Lyonnet D, Andrieu N, Asselain B. [Estimation of individual breast cancer risk: relevance and limits of risk estimation models]. *Bull Cancer.* 2009 Oct;96(10):979-88.
44. Liu YI, Kamaya A, Desser TS, Rubin DL. A bayesian network for differentiating benign from malignant thyroid nodules using sonographic and demographic features. *AJR Am J Roentgenol.* 2011 May;196(5):W598-605.
45. Bates DW, Kuperman GJ, Wang S, Gandhi T, Kittler A, Volk L, et al. Ten commandments for effective clinical decision support: making the practice of evidence-based medicine a reality. *J Am Med Inform Assoc.* 2003 Nov-Dec;10(6):523-30.
46. Lin HC, Wu HC, Chang CH, Li TC, Liang WM, Wang JY. Development of a real-time clinical decision support system upon the Web MVC-based architecture for prostate cancer treatment. *BMC Med Inform Decis Mak.* 2011;11:16.
47. Kawamoto K, Houlihan CA, Balas EA, Lobach DF. Improving clinical practice using clinical decision support systems: a systematic review of trials to identify features critical to success. *BMJ.* 2005 Apr 2;330(7494):765.
48. Schindler JV, Mraz T. Agent-based modeling for real-time decision-support for point-of-distribution managers during influenza mass vaccination. *AMIA Annu Symp Proc.* 2008:1124.

49. Fitzgerald M, Cameron P, Mackenzie C, Farrow N, Scicluna P, Gocentas R, et al. Trauma resuscitation errors and computer-assisted decision support. *Arch Surg*. 2011 Feb;146(2):218-25.
50. Zhang Y, Fong S, Fiaidhi J, Mohammed S. Real-time clinical decision support system with data stream mining. *J Biomed Biotechnol*. 2012;2012:580186.
51. Demner-Fushman D, Chapman WW, McDonald CJ. What can natural language processing do for clinical decision support? *J Biomed Inform*. 2009 Oct;42(5):760-72.
52. Al-Haddad MA, Friedlin J, Kesterson J, Waters JA, Aguilar-Saavedra JR, Schmidt CM. Natural language processing for the development of a clinical registry: a validation study in intraductal papillary mucinous neoplasms. *HPB (Oxford)*. 2010 Dec;12(10):688-95.
53. Barrett N, Weber-Jahnke JH. Applying natural language processing toolkits to electronic health records - an experience report. *Stud Health Technol Inform*. 2009;143:441-6.
54. Baud R, Ruch P. The future of natural language processing for biomedical applications. *Int J Med Inform*. 2002 Dec 4;67(1-3):1-5.
55. Cowie J, Lehnert W. Information extraction. *Commun ACM*. 1996;39(1):80-91.
56. Feldman R, Regev Y, Finkelstein-Landau M, Hurvitz E, Kogan B. Mining biomedical literature using information extraction. *Current Drug Discovery*. 2002(OCT):19-23.
57. Feldman R, Regev Y, Gorodetsky M. A modular information extraction system. *Intelligent Data Analysis*. 2008;12(1):51-71.
58. Habib MS, Kalita J. Scalable biomedical Named Entity Recognition: investigation of a database-supported SVM approach. *Int J Bioinform Res Appl*. 2010;6(2):191-208.
59. Meystre SM, Haug PJ. Comparing natural language processing tools to extract medical problems from narrative text. *AMIA Annu Symp Proc*. 2005:525-9.
60. Langlotz CP. ACR BI-RADS for breast imaging communication: a roadmap for the rest of radiology. *J Am Coll Radiol*. 2009 Dec;6(12):861-3.
61. Buchbinder SS, Leichter IS, Lederman RB, Novak B, Bamberger PN, Sklair-Levy M, et al. Computer-aided classification of BI-RADS category 3 breast lesions. *Radiology*. 2004 Mar;230(3):820-3.
62. Mykowiecka A, Marciniak M, Kupsc A. Rule-based information extraction from patients' clinical data. *J Biomed Inform*. 2009 Oct;42(5):923-36.

63. Nassif H, Woods R, Burnside E, Ayvaci M, Shavlik J, Page D. Information Extraction for Clinical Data Mining: A Mammography Case Study. Proc IEEE Int Conf Data Min. 2009:37-42.
64. Percha B, Nassif H, Lipson J, Burnside E, Rubin D. Automatic classification of mammography reports by BI-RADS breast tissue composition class. J Am Med Inform Assoc. 2012 Sep-Oct;19(5):913-6.
65. Nadkarni PM, Ohno-Machado L, Chapman WW. Natural language processing: an introduction. J Am Med Inform Assoc. 2011 Sep-Oct;18(5):544-51.
66. Cunningham H, Tablan V, Roberts A, Bontcheva K. Getting more out of biomedical documents with GATE's full lifecycle open source text analytics. PLoS Comput Biol. 2013 Feb;9(2):e1002854.
67. Harkema H, Dowling JN, Thornblade T, Chapman WW. ConText: an algorithm for determining negation, experiencer, and temporal status from clinical reports. J Biomed Inform. 2009 Oct;42(5):839-51.
68. Zheng J, Chapman WW, Crowley RS, Savova GK. Coreference resolution: a review of general methodologies and applications in the clinical domain. J Biomed Inform. 2011 Dec;44(6):1113-22.
69. Gooch P, Roudsari A. Lexical patterns, features and knowledge resources for coreference resolution in clinical notes. J Biomed Inform. 2012 Oct;45(5):901-12.
70. Corp. NS. Netica Tutorials [EB/OL].
71. Do CB, Batzoglu S. What is the expectation maximization algorithm? Nat Biotech. [10.1038/nbt1406]. 2008;26(8):897-9.
72. Maynard D, Peters W, Li Y. Metrics for evaluation of ontology-based information extraction. International world wide web conference. 2006.
73. Burnside E, Rubin D, Strasberg H. Automated indexing of mammography reports using linear least squares fit. Cars 2000: Computer Assisted Radiology and Surgery. 2000;1214:449-54.
74. Jain NL, Friedman C. Identification of findings suspicious for breast cancer based on natural language processing of mammogram reports. Proc AMIA Annu Fall Symp. 1997:829-33.
75. Nassif H, Woods R, Burnside E, Ayvaci M, Shavlik J, Page D. Information Extraction for Clinical Data Mining: A Mammography Case Study. 2009 Ieee International Conference on Data Mining Workshops (Icdmw 2009). 2009:37-42.
76. Esuli A, Marcheggiani D, Sebastiani F. An enhanced CRFs-based system for information extraction from radiology reports. J Biomed Inform. 2013 Feb 11.

77. Sevenster M, van Ommering R, Qian Y. Automatically correlating clinical findings and body locations in radiology reports using MedLEE. *J Digit Imaging*. 2012 Apr;25(2):240-9.
78. Meystre S, Haug PJ. Natural language processing to extract medical problems from electronic clinical documents: performance evaluation. *J Biomed Inform*. 2006 Dec;39(6):589-99.
79. Meystre SM, Savova GK, Kipper-Schuler KC, Hurdle JF. Extracting information from textual documents in the electronic health record: a review of recent research. *Yearb Med Inform*. 2008:128-44.
80. Liu F, Weng C, Yu H. Natural Language Processing, Electronic Health Records, and Clinical Research. In: Richesson RL, Andrews JE, editors. *Clinical Research Informatics*: Springer London; 2012. p. 293-310.
81. Friedman C, Rindfleisch TC, Corn M. Natural language processing: State of the art and prospects for significant progress, a workshop sponsored by the National Library of Medicine. *J Biomed Inform*. 2013 Jun 25.
82. Sarawagi S. Information Extraction. *Found Trends databases*. 2008;1(3):261-377.
83. Greenes RA. *Clinical Decision Support: The Road to Broad Adoption*: Elsevier Science; 2014.
84. Aronson AR, Lang FM. An overview of MetaMap: historical perspective and recent advances. *J Am Med Inform Assoc*. 2010 May-Jun;17(3):229-36.
85. Friedman C, Alderson PO, Austin JH, Cimino JJ, Johnson SB. A general natural-language text processor for clinical radiology. *J Am Med Inform Assoc*. 1994 Mar-Apr;1(2):161-74.
86. Savova GK, Masanz JJ, Ogren PV, Zheng J, Sohn S, Kipper-Schuler KC, et al. Mayo clinical Text Analysis and Knowledge Extraction System (cTAKES): architecture, component evaluation and applications. *J Am Med Inform Assoc*. 2010 Sep-Oct;17(5):507-13.
87. Zeng QT, Goryachev S, Weiss S, Sordo M, Murphy SN, Lazarus R. Extracting principal diagnosis, co-morbidity and smoking status for asthma research: evaluation of a natural language processing system. *BMC Med Inform Decis Mak*. 2006;6:30.
88. Crowley RS, Castine M, Mitchell K, Chavan G, McSherry T, Feldman M. caTIES: a grid based system for coding and retrieval of surgical pathology reports and tissue specimens in support of translational research. *J Am Med Inform Assoc*. 2010 May-Jun;17(3):253-64.

89. Denny JC, Irani PR, Wehbe FH, Smithers JD, Spickard A, 3rd. The KnowledgeMap project: development of a concept-based medical school curriculum database. *AMIA Annu Symp Proc.* 2003:195-9.
90. Hahn U, Romacker M, Schulz S. MEDSYNDIKATE--a natural language system for the extraction of medical information from findings reports. *Int J Med Inform.* 2002 Dec 4;67(1-3):63-74.
91. Mendonca EA, Haas J, Shagina L, Larson E, Friedman C. Extracting information on pneumonia in infants using natural language processing of radiology reports. *J Biomed Inform.* 2005 Aug;38(4):314-21.
92. Waghlikar K, Sohn S, Wu S, Kaggal V, Buehler S, Greenes RA, et al. Workflow-based Data Reconciliation for Clinical Decision Support: Case of Colorectal Cancer Screening and Surveillance. *AMIA Jt Summits Transl Sci Proc.* 2013;2013:269-73.
93. Waghlikar KB, MacLaughlin KL, Henry MR, Greenes RA, Hankey RA, Liu H, et al. Clinical decision support with automated text processing for cervical cancer screening. *J Am Med Inform Assoc.* 2012 Sep-Oct;19(5):833-9.
94. Friedman C. A broad-coverage natural language processing system. *Proc AMIA Symp.* 2000:270-4.
95. Burnside ER, D. ; Strasberg, H. Automated indexing of mammography reports using linear least squares fit INTERNATIONAL CONGRESS SERIES - AMSTERDAM- EXCERPTA MEDICA THEN ELSEVIER SCIENCE Computer assisted radiology and surgery; CARS 2000 International congress; 14th, Computer assisted radiology and surgery; CARS 2000 2000.
96. Nassif H, Cunha F, Moreira IC, Cruz-Correia R, Sousa E, Page D, et al. Extracting BI-RADS Features from Portuguese Clinical Texts. *Proceedings (IEEE Int Conf Bioinformatics Biomed).* 2012:1-4.
97. Sippo DA, Warden GI, Andriole KP, Lacson R, Ikuta I, Birdwell RL, et al. Automated extraction of BI-RADS final assessment categories from radiology reports with natural language processing. *J Digit Imaging.* 2013 Oct;26(5):989-94.
98. Fiszman M, Chapman WW, Aronsky D, Evans RS, Haug PJ. Automatic detection of acute bacterial pneumonia from chest X-ray reports. *J Am Med Inform Assoc.* 2000 Nov-Dec;7(6):593-604.
99. Bozkurt S, Lipson JA, Senol U, Rubin DL. Automatic abstraction of imaging observations with their characteristics from mammography reports. *J Am Med Inform Assoc.* 2014 Oct 28.

ÖZGEÇMİŞ

Selen Bozkurt, 2 Temmuz 1982 yılında İzmir'de doğdu. İlk ve orta öğrenimini İzmir'de tamamladı. 2001 yılında lisans eğitimine başladığı 9 Eylül Üniversitesi Fen ve Edebiyat Fakültesi İngilizce İstatistik bölümünden 2005 yılında mezun oldu. 2005 yılı Eylül döneminde Akdeniz Üniversitesi Sağlık Bilimleri Enstitüsü Biyoistatistik ve Tıp Bilişimi Anabilim Dalı'nda yüksek lisans ve ardından doktora eğitimine başladı. Halen burada araştırma görevlisi olarak çalışmaktadır. Yabancı dili İngilizcedir.

EKLER

Jape ile Yazılmış Rapordaki Bölüm Başlıklarını Bulan Gramer Örneği

```
// #####
//
//      Section Header Detector
//
// #####

phase: SectionHeader
Input: Lookup Token
options: control = All

Rule: createSectionHeaderFromLookup
Priority:2

(
  ({Lookup.majorType==Report_Section}):sectionHeader
  ({Token.string==":"})
)

-->
{
  gate.AnnotationSet annSet = (gate.AnnotationSet)
bindings.get("sectionHeader");
  gate.Annotation ann = (gate.Annotation)
annSet.iterator().next();
  FeatureMap lookupFeatures = ann.getFeatures();
  gate.FeatureMap features = Factory.newFeatureMap();
    features.put("kind", "header");
    features.put("section",
ann.getFeatures().get("minorType").toString());
    features.putAll(lookupFeatures);
    features.remove("ontology");
  try{
    outputAS.add(annSet.firstNode().getOffset(),
annSet.lastNode().getOffset(),
"SectionHeader", features);
  }catch(InvalidOffsetException e){
    throw new LuckyException(e);
  }
  //remove old
inputAS.removeAll((AnnotationSet)bindings.get("sectionHeader")
);
}
```