

**T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**İNTERAKTİF MAKİNE ÖĞRENMESİ KULLANILARAK,
AKTÖR-METÂ İLİŞKİSİNİN ANALİZİ İLE SAĞLIK GERİ
ÖDEME SİSTEMLERİNDE PROAKTİF SUİSTİMAL TESPİT
MODELİ**

**İLKER KÖSE
DOKTORA TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**GEBZE
2015**

**T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**İNTERAKTİF MAKİNE ÖĞRENMESİ
KULLANILARAK, AKTÖR-METÂ
İLİŞKİSİNİN ANALİZİ İLE SAĞLIK GERİ
ÖDEME SİSTEMLERİNDE PROAKTİF
SUISTİMAL TESPİT MODELİ**

**İLKER KÖSE
DOKTORA TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**DANIŞMANI
DOÇ. DR. MEHMET GÖKTÜRK**

**GEBZE
2015**

T.R.
GEBZE TECHNICAL UNIVERSITY
GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

**AN INTERACTIVE MACHINE-
LEARNING-BASED ELECTRONIC FRAUD
AND ABUSE DETECTION SYSTEM IN
HEALTHCARE INSURANCE**

İLKER KÖSE
**A THESIS SUBMITTED FOR THE DEGREE OF
DOCTOR OF PHILOSOPHY**
DEPARTMENT OF COMPUTER ENGINEERING

THESIS SUPERVISOR
ASSOC. PROF. DR. MEHMET GÖKTÜRK

GEBZE

2015



GTÜ Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 12/10/2015 tarih ve 2015/62 sayılı kararıyla oluşturulan jüri tarafından 09/11/2015 tarihinde tez savunma sınavı yapılan İlker KÖSE'nin tez çalışması Bilgisayar Mühendisliği Anabilim Dalında DOKTORA tezi olarak kabul edilmiştir.

JÜRİ

ÜYE

(TEZ DANIŞMANI) : Doç. Dr. Mehmet GÖKTÜRK

ÜYE

: Doç. Dr. Fatih Erdoğan SEVİLGİN

ÜYE

: Doç. Dr. İlyas KANDEMİR

ÜYE

: Doç. Dr. Kemal KILIÇ

ÜYE

: Doç. Dr. Nihat KASAP

ONAY

Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun
...../...../..... tarih ve/..... sayılı kararı.

İMZA/MÜHÜR

ÖZET

Sağlık alanında sahtecilik ve suistimal tespiti, veri madenciliği çalışmaları açısından en zor problemlerdendir. Çalışmaların çoğunda yeterli ve gerçek veriye ulaşma zorluğu yaşandığından, çoğunlukla sadece belirli aktör veya sağlık hizmetleri ele alınarak problemin sınırlı bir durumu üzerinde çalışılmıştır. Bu çalışmamızın amacı, sahtecilik ve suistimal vakalarını, ilgili vakaya dâhil olan aktör ve metâlardan (sağlık hizmeti, ilaç, vb.) bağımsız olarak tespit edebilen, anormal davranışların parçalı doğasını dikkate alan ve yeni sahtecilik türleri için kolaylıkla adapte edilebilen özgün bir uygulama çerçevesi önermektir. Çalışmada, etkileşimli makina öğrenmesi yöntemi kullanılarak uzman bilgisi gerekli tüm alanlarda çalışmaya aktarılmıştır. Modelin doğruluğunu artırmak için çalışmada iyi bilinen yöntemler kullanılmıştır. Aktör ve niteliklere ağırlık atamak için ikilik düzende çiftleri karşılaştırma, benzer aktörlerin kümelenmesi için beklenti çoklama -BK, proaktif risk hesaplayabilmek için iki kademeli veri ambarı, detaylı analiz için ileri görselleştirme araçları ile risk hesaplamasında z-skor ve standardizasyon kullanımı bu yöntemlerden öne çıkanlardır. Alan uzmanları, senaryo hikâyelerini yazarak 6 farklı sahtecilik ve suistimal davranış türü tanımlamışlardır. Önerilen uygulama çerçevesi, gerçek ilaç reçete verileri üzerinde altı farklı sahtecilik ve suistimal davranışı için reçetede tüm aktör ve metâları kapsayacak şekilde deneysel süreçlerden geçirilmiştir. Her deneyin Area Under Curve (AUC) ve maliyet etkinlik derecesi ölçülmüştür. Önerilen model ile hem proaktif; hem de retrospektif tespiti ve analize imkân sağlayan eFAD™ adında bir ürün geliştirilmiş ve alan uzmanlarının eFAD tarafından tespit edilen şüpheli işlemlerin delillerini inceleyerek nihai karar hızlıca ulaşmaları sağlanmıştır. eFAD Suite, Türkiye’de iki ayrı geri ödeme kurumu tarafından ilaç reçeteleri üzerinde tespit ve delillendirme amacıyla kullanılmıştır.

Anahtar Kelimeler: Karar Destek Sistemleri, Sahtecilik Tespiti, Sağlık Sigortası, Etkileşimli Makine Öğrenmesi, Veri Madenciliği.

SUMMARY

Detecting fraudulent and abusive cases in healthcare is one of the most challenging problems for data mining studies. However, most studies have a shortage of real data and focus on a limited version of the problem by covering only a definite actor and commodities, such as healthcare service, disease, etc. The purpose of this study is to model a novel framework capable of detecting the fraudulent and abusive cases independently from the actors and commodities involved in the claims, considering the fragmented nature of the fraudulent and abusive behaviors and having an extensible structure to introduce new fraud and abuse types. Interactive machine learning incorporating experts' knowledge in an unsupervised setting is utilized. To increase the accuracy of the framework, several well-known methods are utilized, such as the binary pairwise comparison for weighting the actors and attributes, expectation maximization for clustering similar actors, two-stage data warehousing for proactive risk calculations, visualization tools for effective analyzing, and z-scores to calculate the risks. The experts define six different abnormal behavior types using storyboards. The proposed framework is evaluated with real-life data for defined abnormal behavior types for prescriptions by covering all relevant actors and commodities. The experiment iterations are evaluated by measuring the AUC and cost saving rates. eFAD™ is developed by using the proposed model to make both proactive and retrospective analysis and support the experts for fact-finding processes. eFAD is utilized by a company to produce monthly reports indicating abnormal behaviors for two insurance companies in Turkey.

Keywords: Decision Support Systems, Fraud Detection, Health Insurance, Interactive Machine Learning, Data Mining.

TEŞEKKÜR

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından TEYDEB-3090145 numaralı projesi kapsamında verilen hibe ile desteklenmiştir. Çalışmada destek ve katkısı bulunan Sabancı Üniversitesinden, Doç. Dr. Kemal KILIÇ, Prof. Aytül ERÇİL, Doç. Dr. Yücel SAYGIN ve Muratcan ÇOBANOĞLU'na, CGM Türkiye'nin Genel Müdürü Dr. Fatma ZAKARYAN'a, değerli destek ve katkıları için teşekkür ederim. Benzer şekilde, çalışmaya medikal ve Sigortacılık bilgi ve tecrübeleri ile katkı sağlayan Ömür SEZER, Dr. Dilek PEKİNER, Dr. İbrahim AKTAŞ, Dr. Adil KARASOY, Dr. Ulaş ÖZÇITAK ve Emine EMRE'ye, teknik çalışmalarda yer alan ve katkı sağlayan değerli uzmanlar Mehmet BİLÇİN, Murat METİN, Emin TÜYLÜCE, Nagehan ACER, Pınar HORUZ ve Tukan ŞENEL'e ayrı ayrı teşekkürlerimi sunarım.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	v
SUMMARY	vi
TEŞEKKÜR	vii
İÇİNDEKİLER	viii
SİMGELER ve KISALTMALAR DİZİNİ	ix
ŞEKİLLER DİZİNİ	x
TABLolar DİZİNİ	xi
1. GİRİŞ	1
2. PROBLEMİN TANIMI	4
2.1. Sağlık Geri Ödeme Modelleri	4
2.2. Elektronik Provizyon Sistemleri ve Kural Motorları	6
2.3. Sahtecilik ve Suistimal Analizi Ne Zaman Gereklidir?	10
2.4. Analize Esas Verilerin Fragmante Doğası	12
2.5. Sahtecilik ve Suistimal Tespit Probleminde Ekosistem	15
3. LİTERATÜRDEKİ ÇALIŞMALAR	19
4. YÖNTEM	28
4.1. Alan Uzmanlarından Bilgisinden Yararlanma; Olay Hikâyeleri	31
4.2. Aktör ve Niteliklerin Ağırlıklandırılması	33
4.3. İki Aşamalı Veri Ambarı	37
4.4. Risk Değerlendirme Motoru	38
4.5. Görselleştirme Aracı	40
5. SONUÇLAR	44
5.1. Doğruluk Modeli	45
5.2. Maliyet Etkinlik Modeli	47
5.3. Sonuçların Karşılaştırılması	49
6. YORUMLAR VE ÖNERİLER	53
KAYNAKLAR	55
ÖZGEÇMİŞ	59
EKLER	60

SİMGELER ve KISALTMALAR DİZİNİ

<u>Simgeler ve</u>	<u>Açıklamalar</u>
<u>Kısaltmalar</u>	
A^b_i	: Aktör
C_j	: Metâ
F_l	: Anomali türü
$G^l(A^b_i)$: Hesaplanan aktör riski
MC_k	: Medikal provizyon talebi
R^l_k	: Hesaplanan provizyon riski
s^l_m	: Niteliğin ağırlığı
$(T_m^b)_{ij}$: Nitelik
$w^{b,l}_i$: Aktörün ağırlığı
AUC	: Area Under Curve
BÇ	: Beklenti Çoklama
ÇKA	: Çok Katmanlı Algılayıcılar
eFAD™	: Electronic Fraud & Abuse Detection
EMÖ	: Etkileşimli Makine Öğrenmesi
GTÜ	: Gebze Teknik Üniversitesi
IML	: Interactive Machine Learning
İDÇK	: İkilik Düzende Çiftleri Karşılaştırma
MLP	: Multilayer Perceptron
ÖDH	: Öz Düzenlemeli Harita
ROC	: Receiver Operating Characteristic
SOM	: Self Organising Map

ŞEKİLLER DİZİNİ

<u>Sekil No:</u>	<u>Sayfa</u>
2.1: Sağlık kurumu ve geri ödeme kurumu arasında ödeme yönetim modelleri.	5
2.2: Sağlık sigortası ödeme modeli.	6
2.3: Elektronik provizyon sistemleri ve provizyon birimlerinin ilişkisi.	7
2.4: Gelişmiş bir ECP sistemi mimarisi.	9
2.5: Sağlık sigorta şirketlerinde işlem döngüsü.	11
2.6: Sigortalının tek bir vakasına ait verilerin fragmente doğası.	13
2.7: Sahtecilik ve suistimal davranışının fragmente doğası.	14
2.8: Bir provizyondaki aktörler ve metalar arasındaki ilişki göstergeleri.	17
4.1: Makine öğrenme modelleri.	29
4.2: eFAD bileşenleri ve mimarisi.	31
4.3: Alan uzmanlarının sistemin girdi ve çıktıları ile etkileşimi.	41
4.4: eFAD Suite – Proaktif ve reaktif modüllere ait ekran görüntüleri.	42
5.1: Deneysel analizin ROC değerleri.	46

TABLolar DİZİNİ

<u>Tablo No:</u>	<u>Sayfa</u>
3.1: Literatürdeki çalışmaların karşılaştırılması.	27
4.1: Deneyde kullanılan niteliklerin sayısı ve türü.	38
5.1: Deneysel analizin doğruluk ve AUC değerleri.	45
5.2: Deneysel analizin maliyet etkinlik hesap yöntemi.	47
5.3: Denizli iline ait veriler.	48
5.4: eFAD sisteminin ideal bir sistemle karşılaştırmalı maliyet etkinliği.	49
5.5: Literatürdeki çalışmaların doğruluk modelleri ve maliyet etkinliklerinin karşılaştırılması.	50
5.6: ZeroR sınıflayıcısının doğruluk değerleri.	51
5.7: eFAD sistemi ile ve ZeroR sınıflayıcısının doğruluk değerleri karşılaştırması.	52

1. GİRİŞ

Geleneksel makine öğrenmesi uygulamalarında, alan uzmanları (aynı zamanda son kullanıcılar) modelleme aşamasında iki noktada çalışmaya dâhil olmaktadır. [1], [2]. Bunlardan ilkinde, alan uzmanları bilgi mühendislerini (knowledge engineers) eğitirler. Böylelikle karar destek sistemlerini geliştiren bilgi mühendisleri, analizde yer alması gereken gereksinimleri, makine öğrenmesi uygulamasının amaçlarını ve eksik verinin nasıl tespit edilip giderilebileceği gibi ilk bakışta bilinemeyecek bilgileri öğrenirler. İkinci noktada ise, alan uzmanlarından makine öğrenmesi temelli sınıflama algoritmalarının çalıştırılabilmesi için öğrenme verilerinin etiketlenmesi istenir. Her iki etkileşim de, farklı gerçek yaşam problemleri için uygulanan veri madenciliği çalışmalarında başarılı şekilde kullanılmışlardır.

Bununla birlikte, savunma, sağlık, biyolojik bilimler (biosciences), vb. alanlarda yürütülen veri madenciliği çalışmalarında alan uzmanları süreçlere daha fazla dâhil olmak istemekte ve yukarıda belirtilen iki noktadaki teması elde edilmesi istenen sonuç için yeterli görmemektedir [1], [3]. Bu nedenle, bu tür alanlardaki uzmanlar, kendi uzmanlıklarını daha fazla kullanmadıkları ve ihtiyaçlarına göre süreci ve yöntemi özelleştiremedikleri durumlarda, geleneksel makine öğrenme sistemlerini kullanmakta genellikle isteksiz davranmaktadırlar. Dahası, her ne kadar bilgisayarlar çok büyük verileri yüksek performansla analiz etme imkânına sahip olsa da, daha az miktardaki veriyi daha detaylı şekilde analiz etmek için insan zekâsı kimi zaman tercih edilebilir durumdadır [1], [4], [5].

Bu tür ihtiyaçların bir sonucu olarak etkileşimli makine öğrenmesi-EMÖ (Interactive Machine Learning – IML) ortaya çıkmış ve araştırma gruplarının dikkatini çekmeyi başarmıştır. Bu yöntem, birlikte kullanıldığı çeşitli insan-bilgisayar etkileşimi ve görselleştirme araçları hızlı bir şekilde alan uzmanlarının model tasarımı aşamalarına doğrudan katkısını artırmış ve çok sayıda pratik uygulamada kullanılmıştır [6], [7], [8]. Alan uzmanları, EMÖ yöntemi ile öğrenme algoritmalarını seçecekleri parametrelerle eğitebilirler, elde edilen sonuçları karşılaştırarak parametrelerde değişiklik yapmaya devam ederek amaçları için en uygun sonuca ulaşabilirler.

Geleneksel makine öğrenmesinde alan uzmanı ile bilgisayar farklı iş adımlarında ve bağımsız olarak çalışırken, EMÖ’de alan uzmanları bilgisayar ile

aynı işi eş zamanlı olarak yürütürler [1], [5]. Bu sayede uzmanlar, bilgisayarın hız ve kapasitesinden yararlanarak verideki gizli bilgi ve ilişkileri görselleştirme araçlarının da yardımıyla elde eder ve buna karşılık olarak makineye ve algoritmaya hangi parametrelerin kullanılacağına dair geri dönüşler sağlar. EMÖ'deki bu etkileşim, özellikle hipotez ve hedeflerin değişime açık olduğu durumlarda oldukça değerli hale gelmektedir.

Bu tez çalışmasındaki temel motivasyon, sağlık sigortacılığı sektöründe, sahtecilik ve suistimal tespiti için güvenilir ve kolay kullanılabilen bir araca olan ihtiyacı karşılamaktır. Çalışmada, EMÖ temelli ve elektronik provizyon sistemleri ile birlikte çalışabilen bir karar destek sistemi geliştirilmiştir. Karar destek sistemi aracı, operasyonel veri tabanındaki her bir provizyon için değer-fonksiyon temelli bir risk ölçümü yöntemi ile risk ataması yaparak şüpheli vakaları tespit etmektedir. Ardından, verilen risk değerinin gerekçelerini görsel bir analiz aracı ile farklı perspektiflerden göstererek alan uzmanlarına vakanın gerçek bir sahtecilik ya da suistimal olması konusunda nihai kararlarını verebilmeleri için destek olmaktadır.

Zaman serisi veya olay serisi verilerine dayalı olarak anomali tespiti temelli bazı çalışmalar olsa da [9], sağlık alanında tek bir provizyon talebindeki verilere bakarak sahtecilik veya suistimal olup olmadığına dair kanaat getirmek oldukça zordur. Bir provizyon talebindeki veriler, sadece tek bir reçete üzerinde erkeğe verilmeyecek bazı ilaçların yer alması gibi kısıtlı durumlarda bize anomali tespiti için bilgi sağlamaktadır [10]. Oysaki özellikle sağlık alanındaki sahtecilik ve suistimal tespiti, ancak ilgili provizyon talebindeki aktörlerin geçmiş işlemlerinin de analiz sırasında dikkate alınması ile mümkün olabilmektedir. Diğer taraftan, oldukça yüksek miktarda işlemsel (transactional) verinin var olması, klasik veri madenciliği yöntemlerinin kullanılması için yapılacak etiketleme çalışmasını da pratikte kısıtlayan önemli bir faktör olarak karşımıza çıkmaktadır. Buna ek olarak, sistem içerisindeki zeki unsurlar (aktörler), sigorta şirketlerinin aldıkları önlemlere karşı davranış değişikliği gösterebilme refleksine sahiptirler. Bu nedenle sahtecilik ve suistimal davranışları, zaman içerisinde değişkenlik gösteren bir doğaya sahip olduğu için, kullanılan yöntemin ve öğrenme sürecinin de sürekli tekrarlanmasını hatta yeniden modellenmesini gerektirebilmektedir [9], [11]. Bu nedenlerden ötürü, sağlık alanında sahtecilik ve suistimal tespiti problemi için, EMÖ yöntemi, klasik makine öğrenmesi yöntemlerine göre çok daha uygun bir çözüm olarak karşımıza çıkmaktadır.

Tez kapsamında geliştirilen model, alan uzmanlarının sahtecilik ve suistimal şüphelisi işlemleri tespiti sırasında izlediği yolu taklit etmeyi esas almıştır. Bu çerçevede öncelikle provizyon talebi içerisindeki aktörlerin her birinin aynı provizyon talebindeki metâlarla (sağlık hizmeti, reçete, vb.) olan ilişkileri aşağıdan yukarıya (bottom up) incelenmektedir. Ardından, yukarıdan aşağıda (top down) bir yaklaşımla uzmanların yöntemi otomatize edilerek önerilen/verilen karara esas olacak delil niteliğindeki bilgiler hazırlanmaktadır. Çalışma sırasında geliştirilen uygulama iskeleti, manuel analiz ihtiyacını ciddi oranda azaltmış, riskli olmadığı düşünülen vakalar elenerek, sadece riski en çok olan vakaların işaretlenmesine olanak sağlamaktadır. Dahası, geliştirilen görselleştirme aracı, kullanıcıların sistem tarafından tespit edilen şüpheli işlemlerin gerçek bir sahtecilik ya da suistimal vakası olup olmadığına karar verebilmesi için her bir vakanın ve o vakada yer alan aktörlerin geçmiş işlemlerinin detaylı şekilde analizine imkân sağlamaktadır. Bu sayede risk hesaplama motorundaki parametrelerde ne tür değişiklikler yapılması gerektiği konusunda uzmanlara yardımcı olmaktadır.

Tez dosyasının bundan sonraki bölümleri şu şekilde organize edilmiştir: Bölüm 2’de, problemin tanımı yapılarak sahtecilik ve suistimal tespit sürecinin doğası anlatılmıştır. Bu bölüm, sağlık ve sigortacılık sistemi konusunda fazla bilgi sahibi olmayan okuyucular için oldukça önemli ve temel bilgiler içermektedir. Bu bölüm, içeriği açısından oldukça normal görünen bir provizyon verisinin, aslında neden bir sahtecilik ya da suistimal işlemler dizisinin parçası olabileceğinin açıklandığı bölümdür. Bölüm 3, literatürdeki çalışmalara ayrılmıştır. Bölüm 4’te ise, tez kapsamında önerilen model ile geliştirilen uygulama çerçevesi tanıtılmaktadır. Modelin doğruluğunun ve başarısının deneysel ölçümleri ve sonuçları ise Bölüm 5’te sunulmaktadır. Tez, yapılan çalışmanın değerlendirilmesi ve ileri çalışmalar hakkındaki öngörüler paylaşılması ile sonuçlanmıştır.

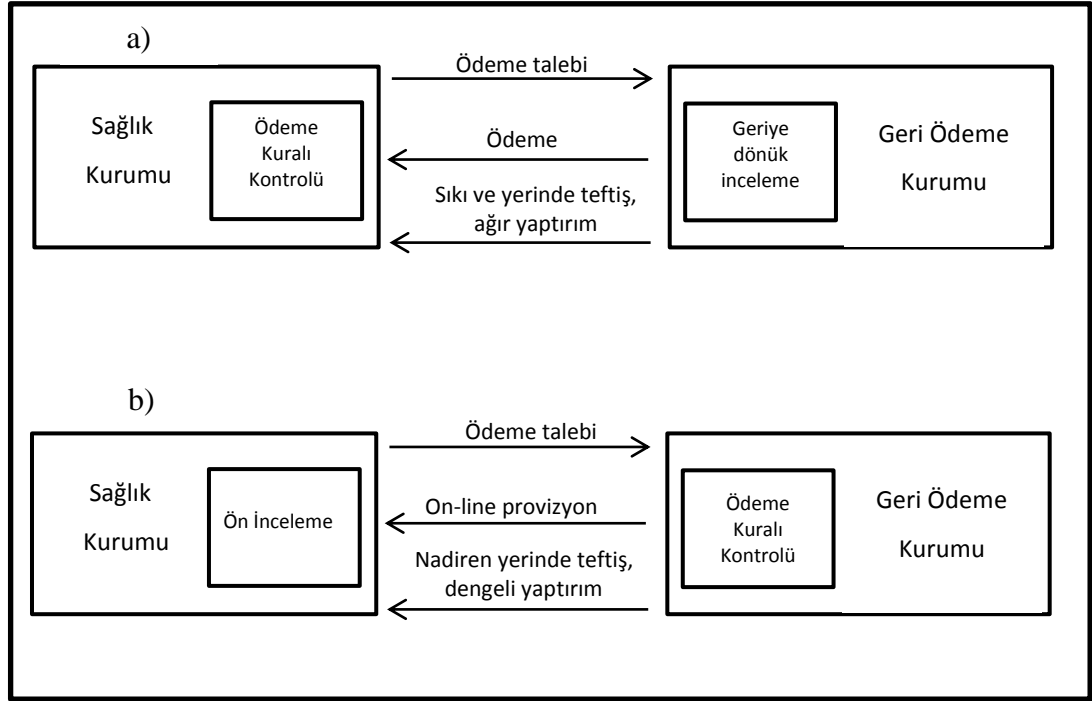
2. PROBLEMİN TANIMI

2.1. Sağlık Geri Ödeme Modelleri

Bireylerin sağlıklı yaşam bilincinin artması, daha uzun ve daha kalitesi bir hayat beklentisi ile sağlık bilimlerindeki gelişmeler, sağlık hizmetlerine ayrılan bütçelerin küresel ekonomi içerisindeki payının ciddi oranda artmasına neden olmuştur. Örneğin A.B.D.'deki Medicare ve Medicaid Merkezi, (Center for Medicare and Medicaid Services, CMS) Amerika'nın 2010 yılı sağlık harcamalarının 2,6 Trilyon USD olduğunu ve bunun gayri sâfi milli hasılanın %17,9'una tekabül ettiğini raporlamaktadır. Sağlık harcamalarındaki artışı kıyaslayabilmek için aynı kurumun 2000 yılı verilerine baktığımızda harcamaların 1,4 Trilyon USD olduğunu ve aynı yıldaki gayri safi milli hasılaya oranının da %13,8 olduğunu görmekteyiz [12]. Tıbbi teknolojilerdeki gelişmeler, aynı zamanda sağlık hizmetlerinde önemli süreç ve ürün çeşitliliğine yol açmıştır. Buna paralel olarak sağlık giderlerinin yükselmesi ve sağlık hizmet çeşitliliğinin artması nedeniyle sağlık sigortacılık sektöründe tüm ödeme süreçlerini yönetebilen çözümler geliştirilmeye başlandı. Bu çerçevede, sigorta şirketlerinin sağlıklı rekabetini sağlamaya katkı sağlayan, özel ve kamu sektöründe sağlık sigortacılığı ödeme yönetim sistemleri geliştirilmiş ve pazardaki yerini almıştır.

Sağlık geri ödeme kontrolü, ülkelerin veya sigorta şirketlerinin ödeme modellerine göre değişiklik göstermektedir. Yaygın karşılaşılan bir modelde, geri ödeyici kurumlar ödeme kurallarını belirli aralıklarla (genellikle yılda bir) ilan eder ve hastanelerin bu kurallara uygun veri göndermesini beklerler (Şekil 2.1.a)). Hastaneler ise ödeme taleplerinin kurallara uygunluğunu talebini göndermeden önce kendi bilgi sistemleri içinde kontrol ederler. Ödeyici kurumlar, bu taleplere ait ödemeleri ciddi bir kontrol yapmaksızın gerçekleştirirler. Buna karşın, genellikle yerinde yaptıkları teftişler sırasında gönderilen verilerle hasta dosyalarının ve ödeme kurallarının uyumunu geriye dönük olarak kontrol ederek gerçekleştirirler ve herhangi bir suistimal tespit ettiklerinde ağır yaptırımlar uygularlar. Şekil 2.1.b)'de gösterilen diğer yaygın modelde ise, geri ödeyici kurum sağlık kurumundan ödeme talebini alır ve anlık olarak kurallara uygunluğunu kontrol eder ve ön onay verir. Tüm işlemlerin tamamlanmasından sonra ödeme öncesinde son bir kez yine hasta

dosyaları ve ödeme kurallarının uygunluğu denetlenir. Haberleşme ve elektronik işlem kapasitesinin artması ile paralel olarak ikinci model giderek daha yaygın hale gelmektedir.



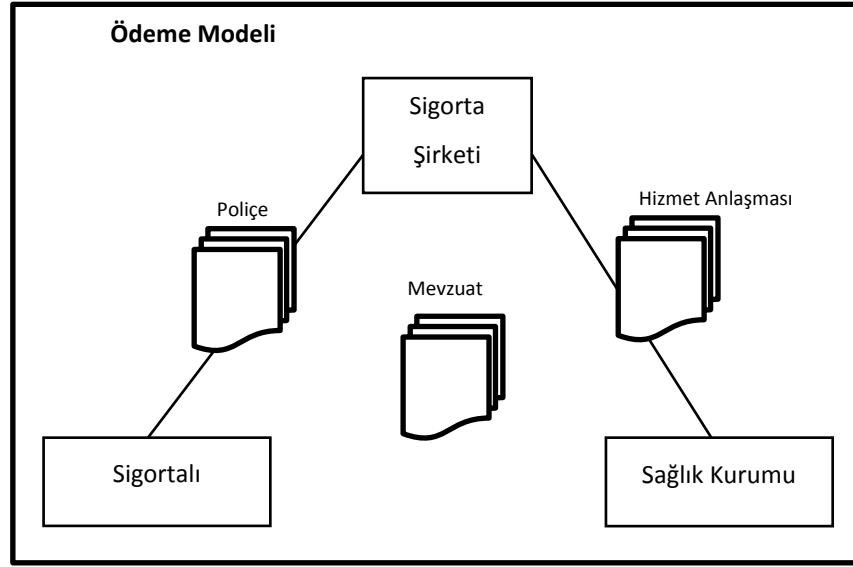
Şekil 2.1: Sağlık kurumu ve geri ödeme kurumu arasında ödeme yönetim modelleri. a) Ödeme kural kontrolünün sağlık kurumunda yapılması. b) Ödeme kural kontrolünün ödeyici kurumda yapılması.

Şekil 2.2’de görüldüğü üzere bir geri ödeme talebinin uygunluğunu belirleyen ve taraflar için bağlayıcı olan iki temel sözleşme vardır:

- i) Poliçe (ya da sosyal güvenlik kurumlarının uygulama esasları, örneğin SGK’nın Sağlık Uygulama Tebliği - SUT)
- ii) Hizmet sözleşmesi.

Poliçe, sigortalının yararlanabileceği sağlık kurumlarını ve varsa teminat, limit, bekleme süresi, özel şart, istisnalar, katkı payı, vb. koşulları belirten ve sigortalı ile ödeyici kurum arasında imzalanan bir sözleşmedir. Hizmet sözleşmeleri ise, sağlık kurumları ile sigorta şirketi arasında imzalanan ve hangi tür poliçeler için hangi hizmetlerin kapsandığını ve bu hizmetlerin fiyat tarifelerini içeren bir sözleşmedir. Bu sözleşmeler dışında ulusal yasal mevzuat ve ödemenin uygunluğunu denetlemeye

yarayacak evrensel medikal kurallar da ödeme kontrolü sırasında ayrıca dikkate alınan diğer unsurlardır.



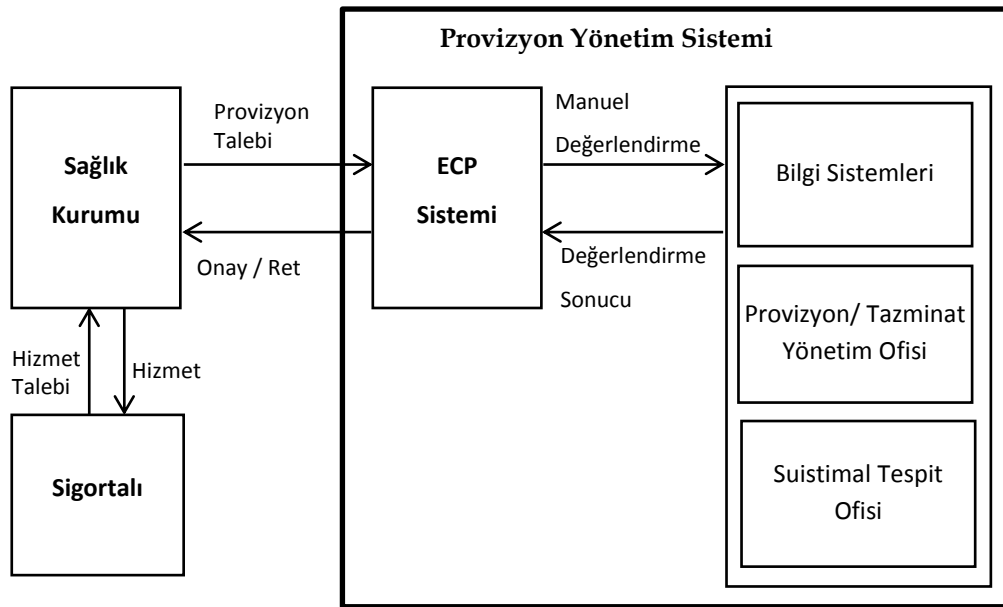
Şekil 2.2: Sağlık sigortası ödeme modeli.

2.2. Elektronik Provizyon Sistemleri ve Kural Motorları

Bir provizyon yönetim sisteminde dört temel bileşen vardır: Sigorta şirketi, hak sahipleri, hizmet sağlayıcıları ve provizyonlar [20]. Bir provizyon yönetim sistemi, talep edilen ödemenin, paydaşlar arasındaki sözleşmelere (sigortalı ile imzalanan poliçeye ve hizmet sağlayıcı ile imzalanan hizmet anlaşmasına) uygunluğunu kontrol eder. Bu kontrollerde, hizmetin türü, içeriği, miktarı, ücreti, hatta kimi durumda talep edilen hizmetin teşhisi koyulan hastalıkla ilişkisinin varlığı gibi çok sayıda parametre gözden geçirilir. Provizyon sürecinin bu şekilde takip edilebilmesi için, sağlık hizmet sunucuları elektronik provizyon veri seti adı verilen yapısal bir veri kümesini ödeyici kuruma iletir.

Çoğu sigorta şirketi, provizyon kurallarını yönetmek için, genellikle bir kural motoruna sahip olan elektronik provizyon sistemi (ECP) kullanmaktadır. Bu sistemlerde kullanılan kural motorları, provizyon talebinde yer alan cinsiyet, tanı, sağlık hizmeti, vb. veriler ile sigortalının poliçesindeki istisna, özel şart, bekleme süresi, vb. kısıtları dikkate alarak bir takım koşulların yerine gelip gelmediğini deterministik şekilde kontrol eder. Bu kontroller arasında, daha önceki provizyonlarla olan ilişkinin kontrol edildiği kısıtlı durumlar, “X işlemi yılda Y defa

ödenir” türü kuralların işletilmesi amacıyla, bunlar da hala deterministik kontrollerdir. Bu tür kural motorları, aynı provizyonda bir araya gelmiş olan aktörlerin (sigortalı, eczacı, doktor, vb.) kendi aralarındaki veya ödemesi talep edilen ilaç veya sağlık hizmeti (metâ) ile geçmişteki ilişkilerini sezgisel yöntemlerle incelemek gibi bir fonksiyon yerine getiremezler. Bu nedenlerdir ki ECP sistemleri provizyon uzmanlarının tüm fonksiyonlarını yerine getirerek onların tamamen yerine geçmezler [21]. Bu durumu oluşturan üç önemli kısıt vardır. İlk olarak tüm olası medikal kuralları ECP sistemleriyle modellemek pratikte son derece zordur. İkinci olarak da provizyon veri setinde yer alan veriler, tüm kuralların kontrol edilmesi için gerekli tüm referansları barındırmamaktadır. Ayrıca tıp bilimindeki alternatif yaklaşımlar, bir ödeme talebinin yerindeliğini de göreceli hale getirebilmektedir ve bazı kuralların otomatik olarak işletmesini imkânsız kılmaktadır. Son olarak, oluşturulan kuralların değişim yönetimi, bu kuralların sayısı ve karmaşıklığı arttıkça, sürecin karmaşıklığı da dramatik şekilde artmaktadır. Tüm bu kısıtlar nedeniyle, sağlık sigorta şirketleri ECP sistemlerinin yanı sıra bir provizyon yönetim ofisi kurarlar ve alan uzmanları çalıştırırlar. ECP sistemlerinin temel işlevi ve provizyon ofisleri ile ilişkileri Şekil 2.3’te belirtilmektedir.



Şekil 2.3: Elektronik provizyon sistemleri ve provizyon birimlerinin ilişkisi.

Bahsedilen zorluklarla karşılaşsa da, kural motoru tabanlı ECP sistemleri hala provizyon yönetiminde en etkin araçlardan başında gelir. ECP sistemlerinin bu

yaygın kullanımı neticesinde elde edilen büyük miktarlardaki yapısal veriler, sahtecilik ve suistimal tespitini de kapsayan çok farklı amaçlar için kullanım imkânı sağlamaktadır.

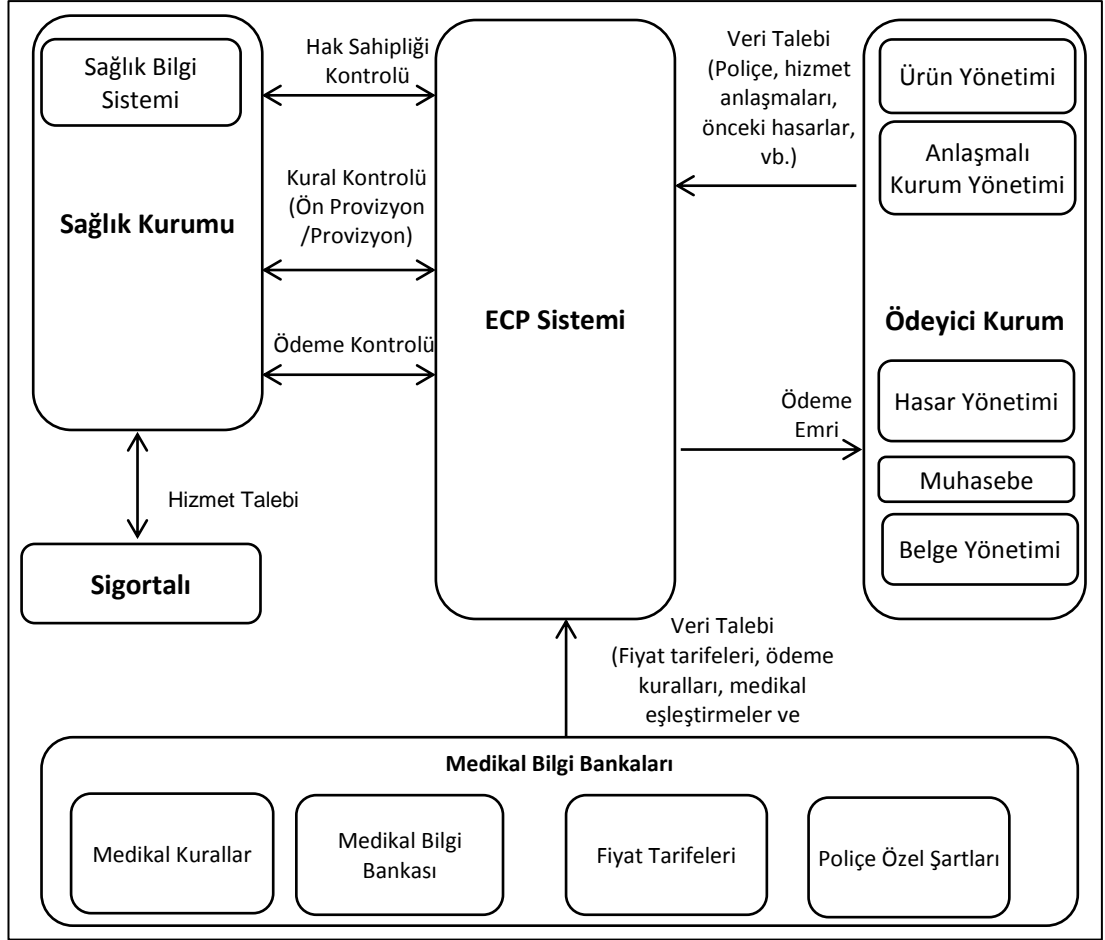
Bütün bu kuralların sağlıklı işletilebilmesi için öncelikle sağlık kurumu tarafından yapısal bir veri setinin ECP'ye ulaştırılması, ECP'nin de ödeyici kurumun diğer bilgi sistemleri ile entegre bir şekilde çalışması gerekmektedir. Örneğin, bir sigortalının bir teminatta limitinin dolup dolmadığının kontrolü ancak poliçe üretim sisteminden çevirim içi sorgulanarak öğrenilebilir. Benzer şekilde, bir sağlık kurumunun hangi işlem için ne kadar ödeme yapılacağına ilişkin güncel bilgisi de anlaşılabilir kurumlar sisteminden sorgulanmalıdır. Bu tür kontrollere ek olarak, ECP sistemlerinin medikal kuralları da işletilebilmesi için, yine entegre olarak çalışacağı güncel bir medikal bilgi bankasına da ihtiyacı vardır. Bu medikal bilgi bankası, kadına, erkeğe veya çocuğa yapılamayacak işlemler/tanımlar, vb. gibi gruplamalarını ve işlem ve teminat listeleri arasındaki eşleştirmeleri barındırır. Bütün bu entegrasyonlar sayesinde kural motorları etkili bir kontrol yapabileceklerdir. Şekil 2.4'te bu şekilde entegre ve gelişmiş bir ECP mimarisi gösterilmektedir.

Kural motorlarının işletilmesi beklenen diğer bir kural türü de, bazı sağlık hizmetlerindeki sayı ve süre kısıtlarının kontrolüdür. Örneğin, bazı işlemlerden yılda sadece bir defa veya ömürde bir defa yapılması gibi kurallar söz konusu olabilmektedir. Bu kural türünün uygulanmasını zorlaştıran şey, kural motorunun sigortalının daha önceki harcama kayıtlarının tamamını kontrol etmesinin gerekmesidir ki, bu durum performans açısından oldukça zorlayıcıdır. ECP sistemlerinde yapılan bir takım performans iyileştirmeleri ile bu tür darboğazların üstesinden gelinmeye çalışılmaktadır.

Bir kural motoru, bu tür sistemlerle entegre olduğu takdirde, şu tür kuralları işletebilecektir:

- Eğer hastanın cinsiyeti erkek ise ve hekimin uzmanlık branşı kadın doğum uzmanlığı ise “RET” (evrensel)
- Eğer ödenmesi istenen işlem sigortalının istisna işlemler listesindeyse “RET” (sigortacılık)
- Eğer ödenmesi istenen işlem gebelik kontrol muayenesi ise ve son 1 ayda gebelik kontrol muayenesi yapılmışsa “RET” (zaman/miktar kısıtı)

- Eğer kişinin gebelik istisnası varsa ve hekimin uzmanlık branşı kadın doğum ise “MANUELE DÜŞÜR” (manuel değerlendirme).



Şekil 2.4: Gelişmiş bir ECP sistemi mimarisi.

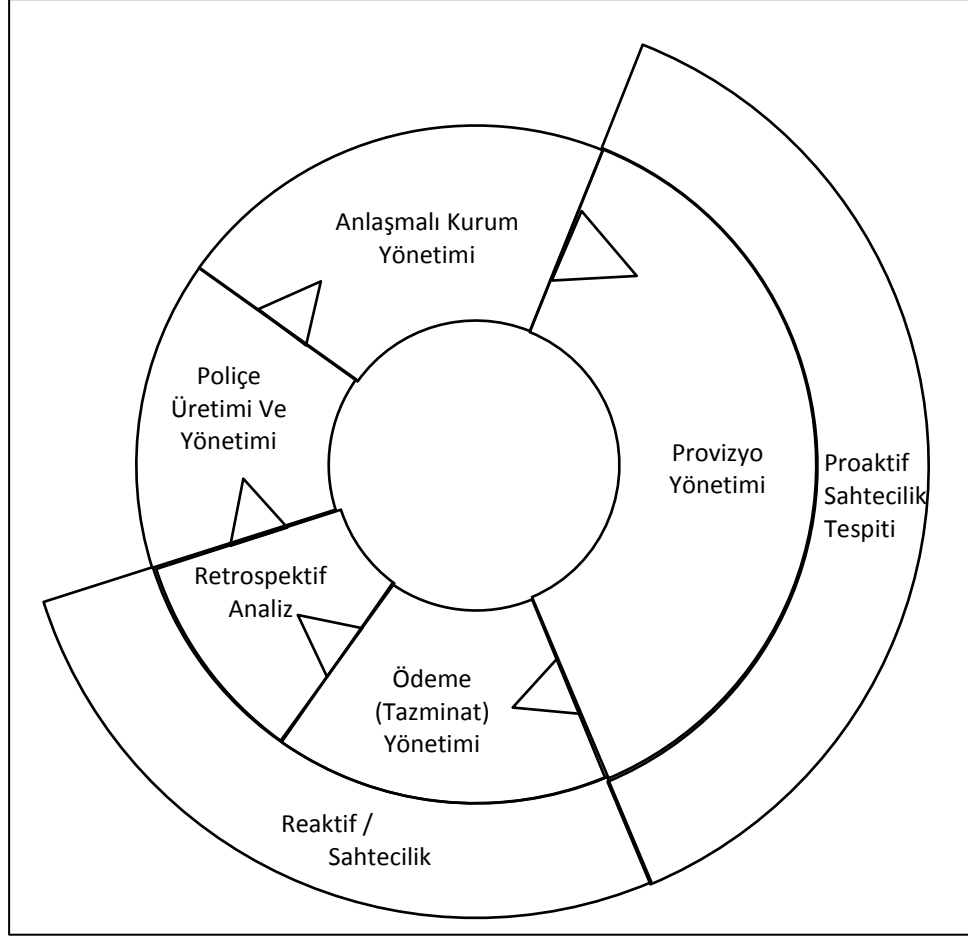
Kural motorlarıyla ilgili diğer önemli bir konu da, kural sonucunda alınan aksiyonlardır. Bir kural cümlesinin “KABUL” şeklinde bir aksiyon almasına gerek yoktur. Zira hiçbir kurala takılmayan bir provizyon kabul edilmiş sayılır. Bu nedenle sadece “KABUL” dışındaki olan durumlar için aksiyon tanımı yapılır. Ancak “KABUL”ün karşıtı olarak sadece “RET” veya “KISMÎ RET” aksiyonu yoktur. Medikal alanda çoğu zaman eldeki provizyon veri setindeki bilgilerle nihai kararı vermek mümkün değildir. Örnek kurallarda da görüleceği üzere, bu tür durumlarda kural motoru “MANUEL DEĞERLENDİR!” şeklinde bir aksiyon alır ve provizyon talebini beklemeye alır. Ardından sağlık kurumunun geri ödeme kurumu ile irtibata geçmesi ve talebin bir uzman tarafından karara bağlanması beklenir. Geri ödeme kurumları, gelişen teknolojilerden yararlanarak bu aksiyonlardan herhangi biri ile

birlikte başka aksiyonları da eş zamanlı alabilmektedir. Örneğin provizyon sonucunun gerekçeleri ile birlikte sigortalıya kısa mesaj olarak gönderilmesi, geri ödeme kurumundaki ilgililere e-posta gönderilerek bazı özel durumlara müdahale etmelerinin istenmesi gibi aksiyonlar tasarlanabilmektedir.

Bir kural motorunun bu kuralları tüm provizyon talepleri için işleteceği ve eş zamanlı çok sayıda talebin olabileceği dikkate alındığında, geri ödeme kurumlarının, kural sayısı ve kuralların karmaşıklığı konusunda hassas olması gerekmektedir. Kuralların çok olması hastanın sağlık kurumundaki bekleme süresini olumsuz etkilerken, az sayıda kural çalıştırılması da ödeme kural yönetimindeki doğruluğu ve hassasiyeti olumsuz etkileyecektir. Benzer bir denge, kural cümlelerindeki aksiyonlar için de söz konusudur. MANUELE DÜŞÜR şeklinde aksiyon alan kuralların çok olması, provizyon departmanında daha fazla uzmanın çalışmasını gerektirirken, tersi bir durum da, aksiyonun durumuna göre reddedilmesi gereken bazı provizyonların kabul edilmesine ya da kabul edilmesi gereken bazı provizyonların da reddedilmesine neden olabilmektedir.

2.3. Sahtecilik ve Suistimal Analizi Ne Zaman Gereklidir?

Bir geri ödeme kurumunda sağlık poliçelerinin yıllık olarak düzlenir olması diğer tüm iş süreçlerinin de yıllık olarak tekrarlanması sonucunu doğurmuştur. Yıllık olarak tekrarlanan bu işlem döngüsünde, poliçe üretimi, sağlık kurumları ile anlaşma imzalanması, provizyon, tazminat ve retrospektif analiz şeklinde aşamalar yer alır. Her aşamada farklı ve muhtemelen birbiri ile entegre çalışan operasyonel bilgi sistemleri ile karar destek sistemleri kullanılabilir. Örneğin, poliçe üretim sistemleri poliçe üretimi aşamasında kullanılırken, ECP sistemleri de provizyon aşamasında kullanılır ve üretim sistemleri ile entegre şekilde çalışır. Sahtecilik tespit sistemlerine ise provizyonun değerlendirmeye tabi tutulduğu, i) provizyon talebi yapıldığında, ii) daha önce onayı verilen provizyonlar için sağlık kurumuna ödeme yapılmadan hemen önce ve iii) yıl boyunca zaman zaman yapılan retrospektif analizlerde ihtiyaç duyulmaktadır. Bunlardan sadece birincisi ECP sistemleri ile entegre şekilde çalışıp proaktif bir rol oynarken; diğer iki aşamada reaktif veya retrospektif analizlerde anomali tespiti yapmaya yardımcı olmaktadır. Bir sigorta şirketinin yıllık işlem döngüsü ile sahtecilik ve suistimal tespitine ihtiyaç duyduğu aşamalar Şekil 2.5'te temsil edilmektedir.



Şekil 2.5: Sağlık sigorta şirketlerinde işlem döngüsü.

Ödeme kurallarının yönetimi, kural tabanlı elektronik provizyon sistemleri için zor olmayan bir süreçtir. Diğer taraftan, bu sistemler sayesinde biriktirilen yapısal provizyon verileri, sahtecilik ve suistimal tespiti gibi amaçlar için kullanılmaya da elverişlidir. Ne var ki, her ne kadar elde yapısal veriler olsa da, sahtecilik ve suistimal tespiti kural tabanlı sistemlerden daha karmaşık, akıllı, son kullanıcı için sezgisel [13] ve bulguya dayalı yaklaşımlara ihtiyaç duymaktadır.

Elektronik provizyon yönetimi alanında pazarda çok sayıda ürün olmasına rağmen (ECP İlaç¹, Claimer ECP², MediClaim³, vb.) [14], [15], ilerleyen bölümlerde detaylı şekilde ele alınacağı üzere, birkaç kısıtlı deneme dışında sahtecilik ve suistimal tespitine dair pazarda kapsamlı bir çözüm bulunmamaktadır.

Sağlık sigorta şirketlerinde kullanılan ödeme yönetim sistemlerinin çoğu, şüpheli işlemlerin değerlendirilmesi için uzmanların yapacağı manuel

¹ CompuGroup Medical (CGM) tescilli markasıdır

² CompuGroup Medical (CGM) tescilli markasıdır

³ Agito tescilli markasıdır

değerlendirmeye muhtaçtır [16]. Ancak, şüpheli işlemlerin uzmanlar tarafından tek tek incelenmesi performans açısından son derece kötü [11], [17] ve maliyetli bir yöntemdir. Bu nedenle, sigorta şirketleri, elektronik provizyon sistemlerinin ürettiği gerçek verileri kullanarak sahtecilik ve suistimal şüphelisi işlemleri tespit etmeye üzere elektronik sistemler geliştirmektedirler. Sigorta şirketlerinin bu ilgisi, araştırmacıların da son yıllarda bu alanda özellikle veri madenciliği tekniklerini kullanan çalışmalar yapmalarına neden olmuştur.

Tam bu noktada, sahtecilik ve suistimal terimlerinin formal anlamlarını belirtmekte fayda vardır. ABD’de yer alan Ulusal Sağlık Hizmetleri Anti-Sahtecilik Birliği (The National Health Care Anti-Fraud Association (NHCAA)), sahtecilik ve suistimali şu şekilde tanımlar [18]:

“Sağlık hizmetinde sahtecilik, özel ya da tüzel kişinin, kasıtlı bir aldatma ya da yanlış beyanı neticesinde ilgili özel ya da tüzel ya da farklı bir tarafa yetkilendirilmemiş bir fayda sağlayan davranıştır.

Sağlık hizmetlerinde suistimal, finans, iş ve medikal süreçlerde hizmet sunan tarafından yapılan ve sonucunda gereksiz bir ek maliyetin doğmasına neden olan ya da medikal açıdan gerekli olmayan ya da profesyonel yaklaşım ve standartlara uygun olmayan işlemlerin yapılmasıyla fazladan ödeme yapılmasını gerektiren uygulamalardır.”


ABD’deki Federal Araştırma Bürosu (Federal Bureau of Investigation, FBI), kamu ve özel sektördeki sağlık giderlerinin %3 ilâ %10’unun sahtecilik ve suistimal neticesinde olduğunu tahmin etmektedir [19]. Pek çok ülkede sağlık harcamalarının ciddi şekilde artmakta olduğunu dikkate aldığımızda bu oran daha dikkat çekici hale gelmektedir. Bu nedenle suistimal ve sahtecilik tespiti, giderlerini azaltmak için çaba harcayan sigorta şirketleri için oldukça hayati bir konu haline gelmektedir.

Sağlık sigorta sektöründe sahtecilik ve suistimal tespiti problemini anlamak için, öncelikle geri ödeme ve provizyon yönetim araç ve yöntemlerini iyi bir şekilde anlamak gereklidir. Bu nedenle, müteakip başlıklarda bu konu ele alınmaktadır.

2.4. Analize Esas Verilerin Fragmente Doğası

Sahtecilik ve suistimal türü davranışlar genellikle tek bir provizyondan ibaret olmayıp, bir dizi provizyon talebinden oluşur ve sahteciliğin anlaşılması için değerlendirilmekte olan provizyon talebinde yer alan aktörlerin daha önceki işlemleri ile birlikte incelenmesi gerekir [10], [22]. Bunun en önemli gerekçesi, provizyon


verisinin, sigortalıya sunulan sağlık hizmetinin sadece belirli bir kesitini içeriyor olması ve aynı sigortalı için farklı kurumlardan farklı aktörleri içeren provizyonların birbirinden bağımsız olarak gönderilebiliyor olmasıdır. Bu nedenle bir provizyon veri seti, bırakın hastanın daha önceki tedavi süreçlerine dair bilgi vermeyi, hastanın devam eden tedavi sürecindeki vaka bütünlüğünü bile temsil edememektedir. Bir vakaya ait olan ve farklı kurumlardan farklı provizyon talepleri şeklinde ödeme talebi yapılan örnek bir durum Şekil 2.6’da temsil edilmektedir.



Şekil 2.6: Sigortalının tek bir vakasına ait verilerin fragmente doğası.

Örneğin, sahte reçete olarak bilinen bir sahtecilik türünü ele alalım. Buna göre, bir hekimin bir eczacı ile anlaşmalı şekilde belirli bir (veya birden fazla) ilaç firmasının ilaçlarını aynı etki için kullanılan diğer ilaçlara göre çok daha fazla yazdığını düşünelim. Her bir reçete, kendi içinde ilaç-vaka uyumluluğu ve diğer kriterler açısından gayet normal görünecek ve tüm ödeme kurallarından da başarıyla geçecektir. Hâlbuki bu aktörlerin kendilerine benzer olan diğer aktörlerle olan davranış farklılıklarını ele aldığımızda ya da kendi geçmiş işlemleri ile karşılaştırdığımızda davranış değişikliği fark edilebilecektir. Dolayısıyla tek başına ele alındığında gayet normal görünen bir işlem, aslında bir suistimal davranışının tekil bir parçası olabilmektedir. Bu nedenle sahtecilik ve suistimal davranışlara ait

verilerin genellikle fragmente (dağılmış, parçalı) bir şekilde bulunduğunu söyleyebiliriz. Şekil 2.7’de bir provizyon talebinde yer alan aktörlerin daha önceki işlemleri arasında yer alan ve sahtecilik davranışı ile ilişkili olan işlemleri temsil edilmektedir.



Şekil 2.7: Sahtecilik ve suistimal davranışının fragmente doğası.

Sahtecilik ve suistimal davranışlarına ait verilerin fragmente bir şekilde dağılmış olduklarını tespit etmek, bu alanda çözüm geliştirmek için çalışan araştırmacılar için son derece önemlidir. Çünkü provizyon taleplerinde yer alan veri seti çoğu zaman ek başına bir kanaat oluşturulmasına yeterli olmamaktadır. Bu da veri madenciliği ve makine öğrenmesi yöntemleri arasında eğitici öğrenmeye dayalı metotları kullanmamızı sınırlandırmaktadır. Çünkü bu yöntemlerde, bir uzmanın eldeki her bir kayıt için şüpheli/normal, vb. şekilde bir etiketleme yapması beklenmektedir. Oysa yukarıda belirtilen örnekte de açıkça anlaşılacağı üzere, içeriği birbirinin tamamen aynı olan ve içerikleri bakımından normal olan iki reçeteden birisi gerçekten normal bir işlem iken, diğeri devam etmekte olan bir suistimal davranışının bir parçası olabilir [10], [23]. Bu durumda uzmandan nasıl bir etiketleme yapması beklenilebilir? Ancak etiketlenmeye esas olan veri setini, provizyonda yer alan verilerden değil de, bu verilerden türetilmiş ve aktörlerin davranışlarını temsil eden bir veri üzerinde yapılması veri madenciliği yöntemleriyle başarı elde edilmesine yardımcı olabilir.

2.5. Sahtecilik ve Suistimal Tespit Probleminde Ekosistem

Sahtecilik ve suistimal terimlerinin tanımlarını vermeden önce, aşağıdaki temel tanımları yapmakta fayda var:

Tanım 1: Aktör A_i^b , bir provizyon talebine dâhil olan zeki unsuru ifade eder.

Aktör tipi (b indisi ile temsil edilen), sigortalı, doktor ve eczacı şeklinde bir kişi olabileceği gibi, hastane, görüntüleme merkezi, vb. gibi bir sağlık hizmet sunucusu da olabilir. Burada önemli olan, aktörün provizyon talebinde aktif rol üstlenebilmesi ve nitelikli davranış sergileme yeteneği olan zeki bir unsur olmasıdır.

Tanım 2: Metâ C_j , bir provizyon talebinde yer alan, para değeri olan ve ödenmesi istenilen hizmet, ilaç, malzeme vb. kalemleri ifade eder.

Metâlar, kendileriyle çok sıkı ilişkisi olan ve onları temsil etmeye imkân sağlayan niteliklere sahip olabilmektedir. Örneğin bir ilaç, analizin türüne göre ilacı üreten ilaç firması veya ilacın etken maddelerinin Anatomical Therapeutic Chemical (ATC) kodları ile temsil edilebilir.

Tanım 3: Medikal Provizyon, içerisinde aktörler, metâlar ve provizyon talep zamanı bilgisinin yer aldığı bir kümedir, $(\{A_i^b\}, \{C_j\}, t)$.

Aktörler kümesi içerisindeki anahtar aktör hastadır. Nitekim hasta tedavi olmak için farklı doktor veya sağlık kurumlarına müracaat ederken, diğer aktörler, hastayı tedavi etmek için hizmet sunar ve neticede verilen hizmet veya malzeme için ödeme talebinde bulunulur. Eğer herhangi bir sahtecilik veya suistimal söz konusu ise, bu işlem ödemesi talep edilen ve para değeri olan metâlar üzerinden yapılacaktır. Böyle bir davranışın tespiti için de daha önce anlatılanlardan hatırlanacağı üzere, ilgili aktörlerin daha önce ödenmesini talep ettikleri fragmente durumda olan provizyon verilerinin bir araya getirilmesi ve analiz edilmesi gerekmektedir.

Tanım 4: Anormal davranış F_l , fragmante durumda olan bir dizi provizyon talebinin oluşturduğu sahtecilik veya suistimal davranışı ifade eder.

Anormal davranışlar, bu davranışa dâhil olan aktör ve metâlara göre farklı türlere ayrılırlar. Örneğin, ABD'deki Ulusal Sağlık Bakımı Sahtecilikle Mücadele Derneği anormal davranışları aktör türlerine göre şu şekilde gruplandırmıştır [24]: Hizmet sağlayıcıların bazı anormal davranışları:

- Hiç yerine getirilmemiş hizmetlerin fatura edilmesi
- Daha pahalı veya gerekli olmayan hizmetlerin verilmesi
- Tıbbi açıdan gerekli olmayan ve sadece fatura tutarını artırmak üzere bazı hizmetlerin verilmesi
- Sigorta kapsamı içinde olmayan hizmetlerin, medikal açıdan gerekli gösterilerek ödeme talep edilmesi
- Sigortalının teşhis ve tedavi geçmişi ile ilgili yanlış beyanda bulunulması
- Sigortalıların bazı anormal davranışları:
- Daha düşük prim hesaplaması için yanlış beyanda bulunulması
- Sigorta hak sahipliği konusunda yanlış beyanda bulunulması
- Sahte provizyon talebinde bulunulması
- Sigorta şirketinin bazı anormal davranışları:
- Hasar tazminat (ödeme) hesaplarında sahtecilik
- Teminat ve hizmet bildirimlerinde sahtecilik

Tanım 5: Nitelik $(T_m^b)_{ij}$, bir provizyon talebinde bir araya gelen aktör, A_i^b ve metalar, C_j arasındaki ilişkiyi temsil eden metrikleri ifade eder.

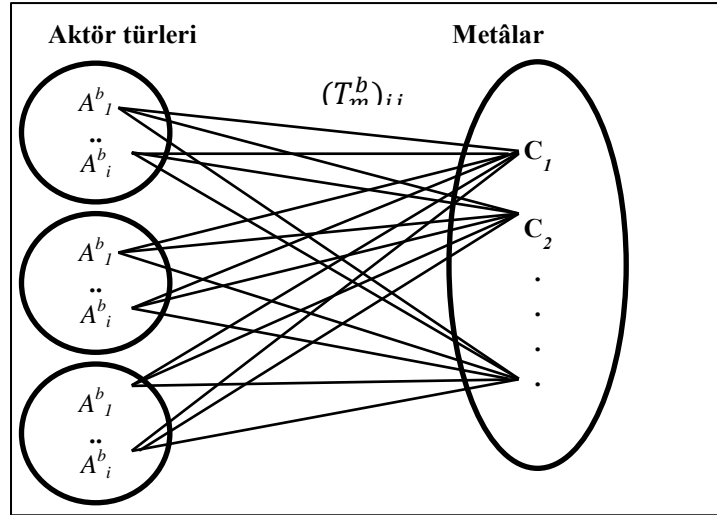
Unutmamak gerekir ki, her bir anormal davranışta aktörler farklı davranışlar gösterirler ve bu davranışlardaki anormallikler kendisini aktörlerle metâlar arasındaki ilişkide gösterir. Dolayısıyla farklı anormal davranışlar için farklı metrik setlerinin kullanılması gerekecektir. Terimde yer alan m , metrik olarak kullanılan niteliği, b aktör tipini, i davranış gösteren aktörü, j kendisiyle etkileşime girilen metâyı ifade eder. Şekil 2.8 her aktör türünün, her metâ ile her bir nitelik açısından sahip olduğu değeri temsil etmektedir.

Tanım 6: Proaktif yaklaşım: Genellikle provizyon departmanlarında kullanılan ve provizyon taleplerinin çevirim içi kontrol edilmesine imkan sağlayan yüksek performanslı çözümlerdir.

Bu çözümler, sadece provizyonun riski ile ilgili bir karar üretmekle kalmaz, ürettikleri kararın doğrulanması için gerekli delil ve bilgileri de provizyon uzmanlarına sunarlar.

Tanım 7: Reaktif/retrospektif yaklaşım: Genellikle tazminat ve hasar analizi departmanları tarafından kullanılan, geriye dönük analizler ve raporlamalar yapan çözümlerdir.

Reaktif yaklaşımın çevirim içi çözüm üretmesi beklenmese de, gerekli bilgileri sunarken kullanıcıyı tatmin edecek bir hızda olması beklenir. Eğer, provizyon taleplerini proaktif olarak hesaplayabilen bir sistem varsa, aynı sistem geçmişteki provizyonların da risk değerlendirmesinin yapılmasında kullanılarak reaktif çözümün de risk hesaplama modülü olarak kullanılabilirler.



Şekil 2.8: Bir provizyondaki aktörler ve metalar arasındaki ilişki göstergeleri.

Özet olarak, bir provizyon talebinin anormal bir durum olduğunu tespiti, bu provizyonda yer alan aktörlerin daha önceki provizyonlarında aynı metalarla olan

ilişkilerinin farklı anormal davranış türleri açısından ele alınmasıyla tespit edilebilen karmaşık bir problemidir.

3. LİTERATÜRDEKİ ÇALIŞMALAR

Yukarıda belirtildiği üzere özel ve kamu sağlık hizmet sunumunda sahteciliğin oranının %3 ila %10 arasında tahmin edilmesine rağmen [19], bu alanda yapılan çalışma sayısı fazla değildir. Bu durumun bazı mantıklı sebepleri vardır. Her şeyden önce, sahtecilik tespiti, olabildiğince fazla sayıda kaynaktan toplanmış ve çok büyük miktarda veriye ihtiyaç duymaktadır. Buna karşın, elektronik verilerin kullanımı haberleşme teknolojilerindeki gelişmelere paralel olarak son 10 yıl içerisinde yaygınlaşmaya başlamıştır. İkinci olarak, sağlık alanındaki sahteciliğin keşfi, taşıt sigortası veya kredi kartı sahteciliklerinde olduğundan daha karmaşık bir problemdir. Üçüncü olarak ise her ne kadar sağlık sigortacılığı alanında kısıtlı da olsa bazı çalışmalar yapılmış olsa da, ticari sır boyutu nedeniyle yapılan her çalışmanın sonuçlarını bilimsel merakı giderecek detayda paylaşmak mümkün olmamaktadır. Netice olarak, sektörde sahtecilik durumlarının her çeşidini tespit edebilecek şekilde adapte olabilen bir ürünün hâlâ var olmadığını kesin bir şekilde belirtebiliriz.

Bu çerçevede sayılmak üzere, Phua, Lee, Smith ve Gayler [25], veri madenciliği yöntemleriyle sahtecilik tespiti yapmaya çalışan 51 ayrı çalışmayı incelemiştir. Bu 51 çalışmadan sadece 14 tanesi sigortacılıkla ilgili olup, bunlardan da sadece 5 tanesi sağlık sigortacılığı alanındadır. Aynı çalışma, araştırmacıların çoğunun veri yetersizliğinden, yeterli çalışılmış yöntemlerin azlığından ve literatürde az sayıda yöntemin var olduğundan şikâyet ettiklerini belirtir. Öyle ki, incelenen bu 51 çalışmanın da 2 tanesi sigorta sektöründe olmak üzere sadece 7 tanesi gerçekten uygulamaya alınabilmiş olduğunu belirtir. Bunlar arasında sağlık sigortacılığı alanında uygulanabilmiş bir metot maalesef yoktur.

Daha yakın zamanda yapılan başka bir literatür taramasında ise, 5 tanesi daha önce Phua ve arkadaşları tarafından da incelenmiş olan ve sadece veri madenciliği ile finans sektöründeki sahtecilikleri tespitiye çalışan toplam 49 araştırma incelenmiştir [26].

Sağlık sektöründeki sahtecilik araştırmalarını ele alan ilk çalışma ise, daha önce belirtilen iki literatür taramasından daha önce basılmış ve Li ve arkadaşları tarafından yürütülmüştür [27]. Bu taramada çalışmalar, niteliklerin seçimi, istatistiksel yaklaşım, performans, veri kaynağı ve veri ön işleme yöntemlerine göre

sınıflandırılmıştır. Yine bu araştırma, mevcut yöntemlerin yetersizliğine işaret etmiş ve daha sonraki çalışmalar için pek çok zorluğa dikkat çekmiştir.

Son olarak, bu alanda yapılan en yeni literatür taramasında ise sadece sağlık alanındaki sahtecilik tespitine yönelik 21 çalışma incelenmiş [28] ve bu çalışmalar kullandıkları yöntemlere göre öğreticili, öğreticisiz öğrenme ve hibrit yöntemler kullananlar şeklinde sınıflandırılmıştır.

Bu bölümde bir kısmı belirttiğimiz bu taramalarda da yer alan bazı çalışmaları kısaca ele alacağız. İlk örneğimizde He, Wang, Graco ve Hawkins [29], Avustralya Sigorta Komisyonu -ASK (Australian Health Insurance Commission - HIC) verileri üzerinde sahtecilik ve suistimal üzerinde bir çalışma yapmışlardır [29]. Araştırmacılar, uzmanlar tarafından önerilen 28 ayrı nitelik kullanmışlardır. Aynı uzmanlardan mevcut verinin sahtecilik veya suistimal vakası olup olmadığı yönünde etiketleme yapmaları da istenmiştir. Sınıflayıcı olarak çok katmanlı algılayıcı-ÇKA (multi-layer perceptron - MLP) temelli yapay sinir ağları kullanılan bu çalışmadan veri olarak da 1.500 pratisyen hekimin profiline ait kayıt esas alınmıştır. Ardından, ÇKA ile kendi öz düzenlemeli harita -ÖDH (Self Organizing Map-SOM) yöntemi birlikte denenmiştir. Bu durumda ÖDH, ÇKA ile iki sınıfa ayırma işlemi yapıldıktan sonra sınıflama yapması sağlanmıştır. Araştırmacılar, çalışmanın doğruluk (accuracy) değerlerini AÇK, ÖDH ve AÇK ve ardından ÖDH uygulanan yöntemler için sırasıyla %63,60, %59,87 ve %88,40 olarak vermişlerdir. Burada dikkat çekmek gerekir ki, bu çalışma sağlık sigortacılığında kullanılan provizyon talep verilerini değil; sadece sistemde yer alan aktörlerden birisi olan pratisyen hekimlere ait profil verilerini esas almıştır.

ASK verisi üzerinde araştırma yapan bir diğer çalışma da Williams'a aittir [30]. Williams, kendisinin daha önceki bir çalışmasında geliştirmiş olduğu ve Hot Spots (HS) olarak adlandırmış olduğu veri madenciliği yöntemini sağlık sigortası sektöründe sahtecilik belirleme alanına bir çözüm olarak önermiştir. HS yöntemi, temelde ilginç ve incelemeye değer topakların (nuggets) belirlenmesine dayanmaktadır. Makalede üç aşamadan oluşan bir yöntem önerilmiştir.

İlk aşamada veri kümesi çok değişkenli k-means algoritması kullanılarak kümelere bölünmüştür. İkinci aşamada her bir öznitelik kendi içerisinde bir kümeleme analizine tutularak alt kümelere bölünmüş ve bu alt kümeler temelinde kurallar belirlenmiştir. Son aşamada ise her bir topak için bir ilginçlik skoru bulunmuştur.

Bu yöntemle, 40.000 adet sigortalıya dair vakalar kullanılarak analiz yapılmıştır. Veri kümesinde toplam 30 adet işlenmemiş öznitelik bulunmaktadır. Makalede bu özniteliklere örnek olarak belirtilen yaş, cinsiyet, gibi temel niteliklerin yanı sıra, hastanın bir yıl içerisinde doktora girme sıklığı, gittiği farklı doktor sayısı gibi 20 civarında işlenmiş öznitelik üretilmiştir. Yapılan analiz sonucunda verilerden 280 adet topak yaratılmıştır. Makalede, topaklar için ilginçlik skoru olarak ortalama servis sayısı ve toplam yapılan ödeme miktarları kullanılmıştır. Bu iki skor bazında belli bir değerden yüksek olanların sigorta uzmanları tarafından mercek altına alınması önerilmiştir. Makalede veri sayısı fazla olduğu durumlarda bu tekniğin pek işe yaramayacağı da dile getirilmiştir. Söz konusu çalışmada deneysel sonuçlara yer verilmemekle birlikte, sistemin proaktif bir sonuç üretmediği ve sadece reaktif (retrospektif) kullanıma uygun olduğu da gözlemlenmektedir.

ASK veri tabanındaki son çalışma ise Yamanishi vd. 'ye aittir [31]. Yamanishi vd. sahtecilik probleminin temelde bir aykırılık (outlier) belirleme problemi olduğundan hareketle, geliştirmiş oldukları ve SmartSifter adını verdikleri bir tekniği diğer başka veri kümelerinin yanı sıra Avustralya HIC verisine de uygulanmıştır. SmartSifter, istatistiksel öğrenme kuramını kullanmakta ve temelde kategorik ve sürekli verilerin bir arada bulunma olasılıklarının belirlenmesine dayanmaktadır. SmartSifter'in diğer literatürdeki örneklerden en önemli farkı, eğiticişiz öğrenme tekniği olmasıdır. SmartSifter'da yeni bir veri ulaştığında, çevirim içi eğiticişiz öğrenme yöntemi kullanılarak ona bir olasılık atanmaktadır. Yüksek olasılık yüksek aykırı olma olasılığı anlamına gelmektedir.

Önerilen eğiticişiz öğrenme yönteminin kötü yanlarından bir tanesi hesaplama yapabilmesi için gereken zamanın uzunluğudur. Makalenin başlarında, 90.000 veri, 4 öznitelikli bir veri kümesini 28 saniyede analiz ettiği dile getirilmektedir. Avustralya HIC'dan elde edilen veri, 2 yıl boyunca patoloji servis sağlayıcılarının toplamış olduğu 32 Milyon vektörün olduğu veridir. Bu verinin 4 milyon civarı hastayı, 20.000 civarı doktoru ve 150 civarı patoloji testi sağlayıcısını kapsadığına işaret edilmiştir. Araştırmada analizlerin her bir aktör bazında yapılması önerilmiştir. Makalede sadece patoloji hizmet sağlayıcılarına dair analiz sonuçlar verilmiştir. Diğerlerinin analizlerinin ise devam ettiği dile getirilmektedir. Analizlerde kullanılmakta olan öznitelikler bütünüyle verilmemektedir. Toplam 7 adet öznitelik olduğu söylenmektedir. Bunlardan ilk beş tanesi beş farklı patolojinin oranları (kimyasal, mikrobiyolojik, bağışıklık, doku ve sitoloji), altıncının ise farklı hastaların

sayısı olduğu belirtilmiştir. Yapılan analiz sonucunda tatmin edici sonuçlara ulaşıldığı söylenmiştir. Yamanishi vd. tarafından önerilmekte olan yöntem, makaledeki iddianın aksine proaktif ve gerçek zamanlı kullanılamayacak bir yöntemdir. Şöyle ki makalede önerilen yöntem, şebekeye izinsiz girme verisi analizinde de kullanılmıştır. Bu veri kümesinde 4 Milyon civarında veri vektörü ve 41 öznitelik bulunmaktadır. Makalede böyle büyük bir veri kümesine analiz yapılamayacağını ve analiz için 41 öz niteliğin, en önemli 4 tanesinin seçildiği bildirilmiştir. Veri kümesi bu haliyle bile çok büyük olduğundan dolayı verinin % 83'ü atılmış ve 700.000 civarında veriyle analiz yapılmıştır. Analiz bu haliyle 222 saniye sürmüştür. On binlerce verinin ve onlarca öz niteliğin bulunduğu sağlık sigortası verisinin bu yöntemle gerçek zamanlı analizi çok da mümkün görülmemektedir. Zaten önerilen yöntem sahtecilik belirleme problemine dair geliştirilmiş bir yöntem değildir. Daha çok istatistiksel öğrenme tekniği temelinde geliştirilmiş olan bir yöntemin doğrulanması amacıyla sahtecilik belirleme verisine uygulanmıştır. Yapılan analiz sadece patoloji sağlayıcıları bazında yapılmıştır. İşlem bazında ya da hasta bazında yapılması veri kümesinin büyüklüğü düşünüldüğünde oldukça zor görünmektedir.

HIC veri tabanı üzerinde yapılan bu üç çalışmada da aktör temelli bir analiz yapıldığı görülmektedir. He vd. sadece doktorlar üzerinde bir çalışma yaparken, Williams sigortalılar üzerinde yoğunlaşmış, Yamanishi vd. ise patoloji kliniğindeki işlemler üzerinde aktör temelli bir analiz yaparak bu aktörlerden sadece patoloji servis sağlayıcılarını ele almıştır.

Yamanishi vd. 'den başka, sağlık hizmeti veren kurumları incelemeyi uygun gören diğer bir araştırma ise Major ve Riedinger tarafından yapılmıştır [32]. Major ve Riedinger, sağlık sigortası sisteminde sahtecilik belirlemek amacıyla iki aşamadan oluşan EFD (Electronic Fraud Detection) yöntemini önermişlerdir. EFD'nin operasyonel aşama olarak adlandırılan birinci aşamasında istatistiksel veriler kullanıcılar tarafından analiz edilmiştir ve davranışsal kurallar bulunurken, geliştirme aşaması olarak adlandırılan ikinci aşamada, uzmanların yardımıyla ve makine öğrenme teknikleriyle bilinmeyen kurallar ortaya çıkarılmaktadır. Bu aşamada benzer kurallar geliştirilip veri kümesinde doğrulatılmaya çalışılmaktadır. Doğrulatılan kurallar sisteme eklenmekte, doğrulatılmayanlar ise sistemden silinmektedir. Araştırmacılar, EFD'nin operasyonel aşamasında 5 kategoride 27

davranışsal kural geliřtirmişlerdir. Bu kategoriler, finansal, medikal, mantıksal, zamansal ve mekânsal olarak tanımlanmıştır.

Yazarlar EFD için geliřtirdikleri yöntemi gerçek bir veri kümesine uygulamışlardır. Analiz etmiş oldukları 21.786 sağlık hizmet sağlayıcısından 898 tanesinin uzmanlar tarafından da derinlemesine incelenmesini önermişlerdir. Bu 898 firmadan 23 tanesi için inceleme makalenin yazım tarihinde başlamıştır. İnceleme sonuçları bilinmediđi için yazarlar belirlenen 898 hizmet sağlayıcısının kaçının gerçekten sahtecilik yaptığını kaçının ise yanlış alarm olduğunu bilmediklerini dile getirmişlerdir. Bununla birlikte, yayında verilen ROC eğrisinden bizim yaptığımız hesaplama göre doğruluk değerin %66,53 olduğunu söyleyebiliriz. Makalenin yazıldığı aşamada, yazarların yöntemi uzmanların incelemeye değer gördükleri vakaların yarısından fazlasını aday olarak tespit edememiştir. Yazarların önermiş olduđu EFD yöntemi özünde reaktif bir yöntemdir. Yani geçmişte gerçekleşen işlemlerden biriken verilerin analizine dayanmaktadır ve sahteciliđi ancak yapıldıktan sonra belirleyebilmektedir.

Buraya kadar aktarılan çalışmalar, aktör tabanlı analizler yapıyorken, Ortega vd. tarafından yapılan çalışmada ilk defa bir sağlık işlemi ele alınmıştır ve çalışanların (işçilerin) istirahat raporu alma işlemleri incelenmiştir [33]. Ortega vd. tarafından yapılan araştırmanın çıktısı Şili’de 609.514 kişiyi sigortalamış olan özel sağlık sigortası şirketi Banmedica S.A. ISAPRE tarafından kullanılmaktadır.

Araştırmada standart 2-katmanlı sinir ađları yöntemi kullanılmıştır. Uygulama Banmedica’dan elde edilen iki veri kümesinin birleştirilmesinden elde edilmiştir. Birinci küme 2003 yılına ait ve aralarında 169 tane sahteciliđin olduđu bir veri kümesinden, diđeri ise 2001-2003 arasında toplanmış olan ve her biri kabul, ret, ya da deđiştirilmiş (daha doğrusu azaltılmış) olarak sınıflandırılmış olan 500.000 veriden oluşmaktadır. Korelasyon analizleriyle veriler incelenerek kimi öznitelikler temizlenmiştir. Bu aşamada toplam 125 öznitelik belirlenmiştir. Daha sonraki aşamada işyerinden on günden az rapor verilen bütün veriler kapsam dışı bırakılmış ve veri kümesi oldukça azaltılmıştır. Hatta veri kümesi sigortalı, işveren, bildirim ve doktor bazında alt kümelere ayrılmış ve analizler her birinde ayrı yapılmıştır. Sonuçlar Banmedica ile yapmış oldukları anlaşma geređi yayınlanmamıştır. Sadece işveren bazındaki sonuçların kısmi yayımına izin verilmiştir. Yapılan analizlerde, gerçekte sahtecilik barındıran vakaların sahtecilik olarak sınıflandırılma oranı %73,4, sahtecilik olmayan vakayı sahte olarak belirleme oranı ise %6.9 olarak bulunmuştur.

Önerilen yöntem oldukça sınırlı bir uygulama olan rapor alan kişilerin, ya da onlara rapor veren ya da işverenlerinin sahtecilik yapıp yapmadığını belirlemeye çalışan bir tekniktir. Daha geniş kapsamlı sahtecilik uygulamalarına uygun olup olmadığı bilinmemektedir. Araştırmanın özgün niteliklerinden birisi zaman içerisinde aktörler bazında olasılıkların Sade Bayes Güncellemesi (Naive Bayesian Update) kullanılarak değiştiriliyor olmasıdır. Öte yandan geniş kapsamlı bir sahtecilik belirlemeye yönelik bir karar destek sistemi öngörülmediği için veri görselleştirme söz konusu edilmemiştir.

Sağlık işlemlerinde sahteciliğin tespit edilmesi, işlemler ve işlemde yer alan aktörlerin analiz edilmesi suretiyle söz konusu olabileceği gibi, her bir hastalık bazında pratikte yapılması gereken işlemleri ve o işlemlerin zamanlamalarını gösteren klinik kılavuzların (clinical pathways) kullanılması suretiyle de yapılabilmektedir. Bu yöntemi kullanan araştırmalardan bir tanesi, Yang ve Hwang'a aittir [34]. Çalışmada klinik kılavuzlar kullanıldığı için, öznitelikler oldukça farklı bir yapı içerisinde kurgulanmıştır. Yazarların önerdiği yönteme göre, herhangi bir hastalığın referans kılavuzundan yola çıkarak bir çizge (graph) oluşturulmaktadır. Çizgedeki noktalar (nodes) klinik kılavuzun parçası olan süreçleri, yollar (arcs) ise süreçler arasındaki öncelik-sonralık ilişkisini belirlemektedir. Daha sonra bu çizgenin olabilecek bütün tekli, ikili, üçlü, vb. alt çizgeleri belirlenmiştir. Alt çizgeler ters akışların mümkün olduğu durumları içermemektedir. Bu alt çizgelerin her biri, bir öznitelik olarak ele alınmıştır. Doğal olarak ortalama bir hastalığa yönelik oluşturulacak olan akış yolu çizgesinden 10.000'lerce alt çizge, yani 10.000'lerce öznitelik elde edilecektir. Her bir vakanın, bu alt çizgelere uygun olma ve uygun olmama durumuna göre 1 ve 0'dan oluşan değerler aldığı bir veri vektör hesaplanması önerilmiştir. Bu vektörün son kolonuna uzmanlar tarafından belirlenmiş olan vakanın sahtecilik içerip içermediği bilgisini gösteren 0 ya da 1 eklenilmektedir. Ardından bu özniteliklerin bir filtre (filter approach) yöntemi kullanılarak sayıca azaltılması önerilmiştir. Ardından da C4.5 algoritması kullanılarak sınıflandırma yapılmaktadır.

Çalışmada önerilen yöntemin doğrulanması amacıyla Taiwan'da bir hastanede yer alan Jinekoloji Bölümünde gözlenmiş olan Pelvic Inflammatory Disease (PID) vakalarına yapılan uygulamalar veri olarak alınmıştır. Toplam 2.543 hastanın verisi ön analizden geçilerek temizlenmiş ve 1.812'ye indirilmiştir. Toplam 30.701 öznitelik daha sonraki aşamada filtre algoritması kullanılarak 3.120'ye

indirgenmiştir. Yapılan analizler sonucunda, sahtecilik (ya da yanlış uygulama) olan vakaları doğru olarak belirlenme oranı olarak %64 bulunmuş, sahtecilik olmayan vakaları doğru belirleme oranı olarak ise %67 bulunmuştur. Bu yöntemin uygulanması için öncelikle elde vakalara yapılan işlemlerin her birine dair akış temelli veriye ihtiyaç bulunmaktadır. Belirtilen makalede kullanılan yöntemin hesaplama zamanına dair veriler verilmemiş olsa da, yaratılan öznel sayılarının ne boyutta olduğu düşünülürse oldukça zaman isteyen bir yöntem olduğu kesindir. Öte yandan sahtecilikten çok, yanlış tıbbi uygulamaların belirlenmesine yönelik bir yöntem önerilmektedir. Çünkü akış sırasına uygun olmasına rağmen sahtecilik yapılması oldukça kolaydır. Öte yandan yapılan çalışma hastalık bazında akış yollarına uygunluğu temel aldığından dolayı yerleşim yeri, sağlık merkezi, sigortalı ve işlem bazında analizler mümkün olsa da çok gerçekçi değildir. Bu çalışmanın gerçek bir uygulaması şu an için söz konusu değildir.

Görüleceği üzere, sağlıkta sahteciliğin veya kural dışı davranışların tespiti konusunda yapılan çalışmalar, aktör ve işlem bazlı analizlerden, klinik kılavuzlar ve kuralları esas alan yaklaşımlara kadar oldukça farklı yaklaşımlara sahiptir. Her durumda tespit edilmeye çalışılan şey, kural dışı davranış olduğunu ve bunun tespitinde bir aşamada mutlaka uzman desteğinin gerekli olduğunu değerlendiren Sokol vd. konuya farklı bir yönden yaklaşmışlar ve görselleştirme araçlarını ön plana çıkararak bir çalışma yapmışlardır [35]. Öyle ki, bu çalışmanın, sağlık sigortaları sisteminde kural dışı davranışın tespitinde görselleştirmeyi esas alan tek yaklaşım olduğunu söyleyebiliriz. Bu çalışmada, veri ön işleme, bilgi üretme, veri dönüştürme ve veri denetleme aşamalarına özel bir önem verilmiş, farklı veri görselleştirme teknikleri değerlendirmeye alınmıştır. Çalışmada, makine öğrenme teknikleri kullanılarak verideki örüntülerin belirlenmesi sonucunda bilgi ortaya çıkarılması gelecek araştırma konusu olarak bırakılmıştır. Tartışılan bu görselleştirme yöntemleri proaktif kullanım için uygun görünseler de, araştırmacılar çalışmanın doğruluğu ve başarısı ile ilgili herhangi bir ölçüm veya karşılaştırma sunmamışlardır.

Bu alandaki güncel çalışmalardan birisi, Aral, Güvenir, Sabuncuoğlu ve Akar'a aittir [36]. Bu çalışmada, Sokol'un çalışmasına benzer şekilde bir sağlık hizmeti türü ele alınmış ve bu çerçevede operasyonel veri üzerinden reçete sahtecilikleri incelenmiştir. Özgün bir model olarak öne sürülen çalışmada, nitelik çiftleri arasındaki ilişki esas alınarak anomali tespiti yapılmaya çalışılmıştır. Araştırmada, ilaç adı, fiyat, reçete numarası, yaş, cinsiyet ve tanı nitelikleri arasında, ilaç-tanı, ilaç-

yaş, ilaç-cinsiyet, ilaç-ilaç ve ilaç-maliyet şeklinde 5 adet nitelik çifti belirlenmiş ve her bir çift arasındaki korelasyon ve karşılıklılık matrisleri (corresponding incidence matrice) hesaplanmıştır. Daha sonra bu matrislerden de risk matrisleri oluşturulmuştur. Araştırmacılar, biri kategorik nitelikler, diğeri sıralı nitelikler için olmak üzere risk hesaplaması için iki ayrı metrik belirlemişlerdir. Çalışmanın başarısının ölçülmesi için ise ROC eğrisi ve buradan AUC (Area Under Curve) değeri %85,7 olarak hesaplanmıştır. Bu hesaplamaların yapılabilmesi için de normal olarak uzmanlardan elde edilen verilerinin sahtecilik veya sahtecilik değil şeklinde etiketlenmesi talep edilmiştir.

Diğer bir güncel çalışmada Johnson ve Nagarur tarafından yapılmıştır [37]. Hizmet sunucu profil analizi, demografik analiz, provizyon tutar analizi, sahtecilik ve risk hesaplaması, risk eşik değeri belirleme ve risklerin eşik değere karşılaştırması şeklinde altı aşamadan oluşan bu çalışmada, bir sigorta şirketine ait 878.691 adet gerçek provizyon verisi kullanılmıştır. Bu çalışmada aktör türü olarak sadece doktorlar ele alınmış ve bu çerçevede pratisyen hekimlerin yanı sıra nöroloji, kulak-burun-boğaz ve göz doktorlarından oluşan dört farklı alandan doktorlar incelenmiştir. Çalışmanın başarısı, doğruluk (accuracy), hassasiyet (sensitivity) ve kesinlik (specificity) ölçütleri ile yapılmış ve dört doktor grubu ve çalışmanın her aşaması için ayrı ayrı ölçümlenmiştir. Çalışmanın doğruluk derecesi toplam değerlerin ortalamasına bakıldığında %82 ile %86 arasında değişmektedir. Çalışmanın sonuçları öğreticili ve yarı-öğreticili yapay sinir ağları ile yapılan çalışma sonuçları ile ANOVA yöntemi kullanılarak karşılaştırılmış ve çalışmada elde edilen sonuçların, her iki modelden de kayda değer miktarda daha iyi sonuçlar verdiği ifade edilmiştir.

Çalışmamızla bir şekilde ilgili olan ve yukarıda kısaca bahsedilen çalışmalar, özet olarak Tablo 3.1’de sunulmaktadır. Bu çalışmalardaki temel eksiklikler ya da iyileştirilmesi gereken noktaları şu şekilde sıralayabiliriz:

- Sadece reaktif (retrospektif) yöntemleri kullanmak tek başına bir eksiklik olmasa da, bir yöntemin hem reaktif, hem de proaktif olarak çalışabilmesi bir gelişmişlik göstergesidir. Bu 8 çalışmadan sadece 2 tanesi proaktif olarak çalışabilmektedir.
- Yöntemlerinin çalışma süreleri oldukça yüksektir.
- Yöntemlerde sadece bir aktör veya sağlık hizmeti incelemeye tâbi tutulmuştur. Hâlbuki gerçek hayatta bir sahtecilik olayında birden fazla aktör yer alabilmekte

ve suistimal amacıyla farklı metâlar kullanılabilir. Dolayısıyla problemin gerçek yapısı üzerinde çalışırken bu unsurları da analize dâhil etmek gereklidir.

- Tüm aktör veya provizyon talebi türünü kapsayan herhangi bir model öne sürülemedi.
- Sadece bir sahtecilik veya suistimal davranış türü ele alınmış ve incelenmiştir.
- Yöntemlerin hiçbirinde, aktörlerle metâlar arasındaki ilişki analize dâhil edilmemiştir.
- Çalışmaların sonuçları ve çıktıların gerçek hayat uygulamasında edindiği yerle ilgili bilgiler oldukça kısıtlıdır.

Tablo 3.1: Literatürdeki çalışmaların karşılaştırılması.

Çalışma	Aksiyon Türü	Yaklaşım	Aktör ve İşlemler	Nitelik Sayısı	Yöntem	Mimari
He et. al. (1997)	Reaktif	Aktör tabanlı	Doktor	28	MLP, SOM ve MLP ile SOM	28-15-4 nöronlu oluşan çok katmanlı algılayıcılar (ÇKA) ve ÇKA ile öz düzenlemeli harita (ÖDH)
Williams (1999)	Reaktif	Aktör tabanlı	Sigortalı	50	Hot Spots	K-means kümeleme yöntemini de içeren 3 aşamalı anomali tespit çerçevesi uygulaması
Yamanishi et. al. (2004)	Proaktif	Aktör tabanlı	Patoloji hizmet sunucu	41 (4 tanesi kullanılmış)	İstatistiksel öğrenme	SmartSifter adı verilen ve olasılık hesabına dayalı özel geliştirilmiş bir yöntem
Major and Riedinger (2002)	Reaktif	Aktör tabanlı	Hastane	27	Makine öğrenmesi	Geliştirme ve operasyonel aşamalar için ayrı ayrı geliştirilmiş kural tabanlı model
Ortega et. al. (2006)	Proaktif	İşlem tabanlı	Sağlık raporu	125	2-katmanlı yapay sinir ağı sınıflayıcısı	Çok katmanlı ve ileri beslemeli YSA ve girdi olarak aktör ve provizyon veri tabanlarından elde edilen 4 alt model
Yang and Hwang (2006)	Reaktif	Klinik kılavuz kuralları	PID Hastalığı (Jinekoloji)	NA	C4.5 sınıflayıcı	Klinik kılavuzlara dayalı çizgeler referans alınarak işlemlerin sınıflanması
Sokol et. al. (2001)	Reaktif	İşlem tabanlı	NA	NA	Görsel analiz	Veri temizleme, analiz ve görselleştirme aşamalarından oluşan bir model
Aral K.D. et al. (2012)	Proaktif	İşlem tabanlı	NA	6	Öğreticili öğrenme	Nitelikler arası uzaklığa dayalı risk fonksiyonu tabanlı model
Johnson M.E. et al. (2015)	Reaktif	Aktör tabanlı	KBB, nöroloji, göz uzmanı ve pratisyen hekim	NA	Yoğunluk ve uzaklık analizi	Bağıl yoğunluk oranı ve uzaklığa dayalı altı aşamalı uygulama çerçevesi

Sonuç olarak, ayrı ayrı ele alındıklarında, yukarıda bahsedilen çalışmaların hiçbirinin birden fazla provizyon talebini barındıran sahtecilik ve suistimal davranışlarını tespit edecek bir yaklaşım geliştirmediğini de ifade edebiliriz. Sağlık sigortacılığı sektöründe bu amaçla kullanılan ticari bir ürünün var olmaması da bu tespitimizi desteklemektedir.

4. YÖNTEM

Bu çalışmada, daha önceki araştırmaların karşılaştığı zorluklar ve eksikliklerin üstesinden gelmek üzere özgün bir model geliştirilmiştir. Öncelikle önerilen model aktör ve metadan bağımsızdır. Böylelikle incelenen sahtecilik ve suistimal davranışları sadece bir aktöre veya metâya özel olmak durumunda değildir. Aksine, çok sayıda aktör ve farklı metâlar ile yapılan sahtecilik ve suistimal davranışları tespit edilebilmektedir.

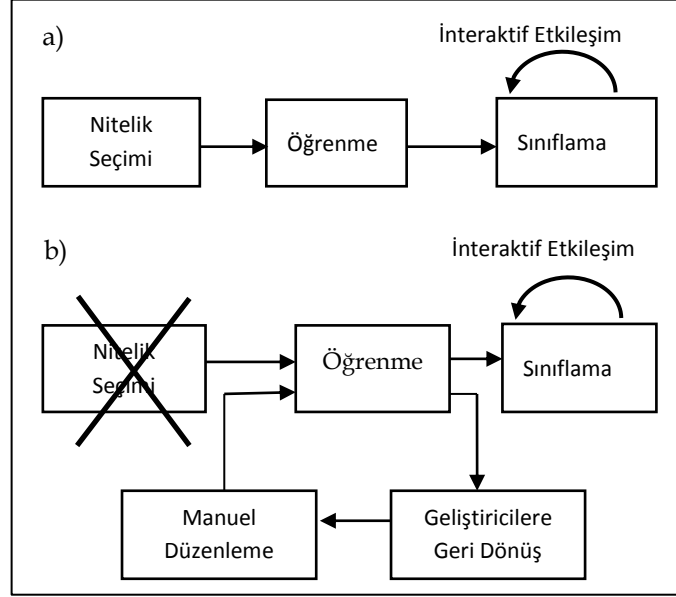
İkinci olarak sağlık sigortacılığında ödeme kuralları ve uygulama esasları değişiklik gösterdiğinden, sahtecilik ve suistimal davranışları da buna paralel olarak değişmektedir. Bu nedenle modele EMÖ yaklaşımı ile uzmanların öğrenme sürecinde dâhil edilmesi ve tecrübelerinin sisteme aktarılması sağlanmıştır. Dahası bu öğrenme süreci sürekli tekrarlanarak değişken olan sahtecilik ve suistimal davranışların daha yakından takip edilmesi mümkün hale getirilmiştir.

Üçüncü olarak, çalışmada aktör ve niteliklerin ağırlıklandırılmasında iyi bilinen bir yöntem olan ikilik düzende çiftleri karşılaştırma (İDÇK) (binary pairwise comparison) [38], benzer aktörlerin kümelenmesi için Beklenti Çoklama-BÇ (Expectation Maximisation-EM) [39] kullanılmıştır. Benzer şekilde hesaplanan risk değerlerinin karşılaştırılması için z-skor hesaplamaları, performans artırımı için iki aşamalı veri ambarı mimarisi ve panel bazlı etkin analiz için in-memory bir görselleştirme aracı (QlikView™) kullanılmıştır.

Dördüncü olarak, önerilen model, fragmente durumdaki provizyon taleplerinin birlikte değerlendirilmesine imkân sağlamaktadır. Hatırlanacağı üzere, içeriği birebir aynı olan iki provizyon talebinin birisi normal iken, diğeri bir dizi provizyon talebinin bir araya gelmesiyle oluşan anormal bir davranışın parçası olabilmekteydi. Bunun için de önceki provizyon taleplerinin de birlikte değerlendirilmesi gerekmektedir. Son olarak geliştirilen model, risk hesaplaması esasına dayalı bir yöntem kullanmaktadır. Ancak benzer yöntemlerin aksine, sadece aktör veya işlemin riskinin hesaplanması değil, aktörlerle metâlar arasındaki ilişkinin riski ele alınmaktadır. Bu sayede riskli olan bir aktörün tüm provizyonları değil, sadece anormal ilişkide olduğu metâların yer aldığı provizyonlar riskli hale gelmekte, diğer provizyon talepleri sistem tarafından riskli kabul edilmemektedir.

Tüm bu hedefleri sağlamak üzere Electronic Fraud and Abuse Detection

(eFAD™)⁴ adında EMÖ tabanlı bir ürün geliştirilmiştir. EMÖ yönteminin klasik makine öğrenmesi sürecinde farklılığı, EMÖ ile ilgili ilk çalışmalardan birini yapan Fails ve Olsen [2] tarafından Şekil 4.1’de belirtildiği şekilde temsil edilmiştir. Buna göre uzmanlar (veya kullanıcılar) öğrenme ve sınıflama sürecinde araç ile sürekli etkileşime girebilmekte ve müdahale edebilmektedirler. Bunu nasıl yaptıkları ile ilgili detaylar ileriki başlıklarda verilecektir.



Şekil 4.1: Makine öğrenme modelleri. a) Klasik makine öğrenmesi süreci. b) Etkileşimli makine öğrenmesi süreci.

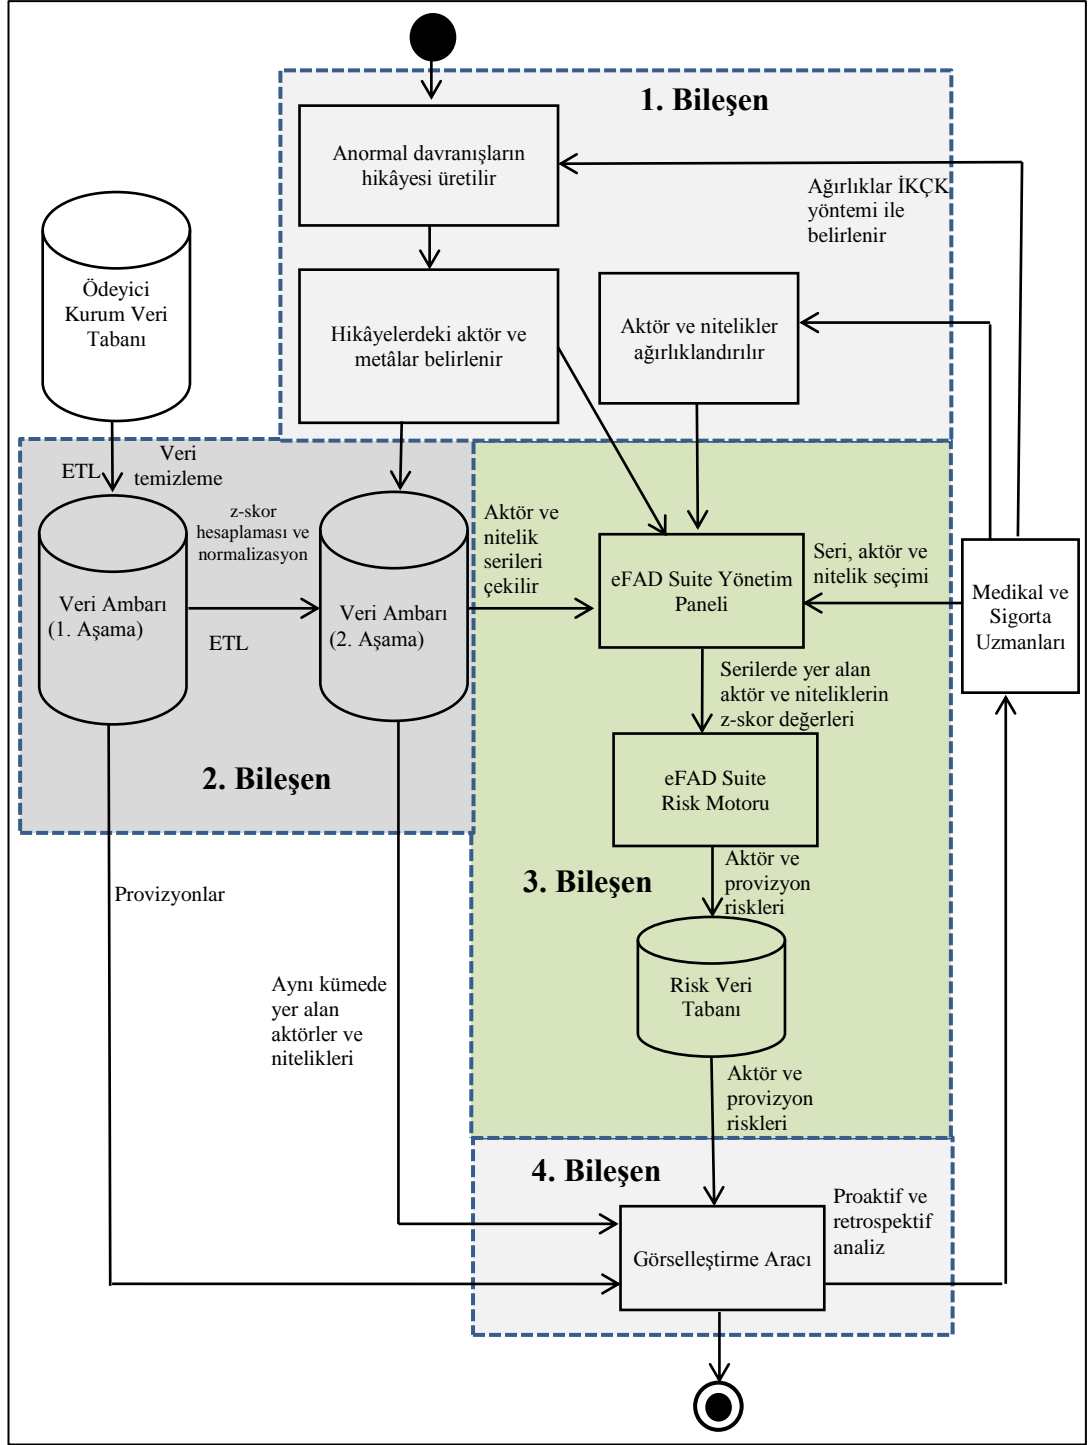
Geliştirilen modeldeki süreçleri daha detaylı anlatmadan önce, modelin temel bileşenleri ile ilgili genel bir gösterim yapmak faydalı olacaktır. Şekil 4.2’de gösterilen bu bileşenlerden birincisi, uzmanların her bir sahtecilik ve suistimal davranışının nasıl geliştiğine dair hikâyeleri yazdıkları ve bu davranışları sergileyen aktörlerin hangi öz niteliklerinde anormal değişiklikler olabileceğini tespit ettikleri ve bu suretle makine öğrenmesi sürecine dâhil oldukları bileşendir.

İkinci bileşen ise iki aşamalı bir veri ambarıdır. Bu veri ambarında, aktörler, metâlar ve uzmanlar tarafından oluşturulan hikâyeler neticesinde öne çıkan ve aktörlerle metâlar arasındaki ilişkileri temsil edecek tüm olası öz niteliklerin ön hesaplanmış değerleri vardır.

⁴ CompuGroup Medical (CGM) tescilli markasıdır

Üçüncü bileşen, her bir provizyon için, o provizyonda yer alan aktörlerle metalar arasındaki ilişkilerin değerleri üzerinden risk hesaplaması yapan risk motorudur.

Dördüncü ve son bileşen ise, her bir sahtecilik türü için aktörlerin ve provizyonların risk durumunu görsel hale getiren görselleştirme aracıdır. Bu görselleştirme aracı, eFAD tarafından yapılan risk hesaplamasının bir çeşit delillendirilmesi amacıyla her bir aktörün metâlarla olan ilişkilerini temsil eden öz niteliklerin grafiklerini göstermekte ve uzmanların (kullanıcıların) diledikleri tarih aralığındaki provizyon taleplerini detaylıca inceleyerek medikal ve sigortacılık açısından da işlemleri incelemesine imkân sağlamaktadır. Benzer şekilde yine bu araç sayesinde, uzmanlar eFAD'ın kullanacağı sahtecilik türlerini ve bu sahtecilik türü için belirleyici olan öz nitelikleri ve onların ağırlıklarını da tanımlayabilmekte veya değiştirerek EMÖ sürecini devam ettirebilmektedirler.



Şekil 4.2: eFAD bileşenleri ve mimarisi.

4.1. Alan Uzmanlarının Bilgisinden Yararlanma; Olay Hikâyeleri

Mevcut uygulamada (şayet bu alana özel geliştirilmiş bir araç kullanılmıyorsa) uzmanlar sahtecilik ve suistimal tespiti için basit raporlama ve analiz araçları

kullanmaktadırlar. Bu uzmanların raporlarda aradıkları ilk şey, göstergelerde beklenenin dışında bir değişim veya değişim eğilimidir. Bu arayış sırasında garip bir durumla karşılaşır, bu defa bu göstergeyi anormal hale getiren sebepleri anlayabilmek için ilgili gördüğü diğer göstergeleri ve nihayet provizyon verisini incelemeye gayret ederler. Son olarak da bu gösterge(ler)deki anomalinin sebebi olan provizyonları bulup onların detayına bakarak medikal ve sigortacılık açısından durumu değerlendirir ve nihayet bu provizyon seti ile ortaya çıkan durumun riskli bir durum olup olmadığına karar verir. Ardından da varılan karara göre de mevzuat veya yasalar çerçevesinde uygun aksiyon alınır.

Geliştirilen modelde, uzmanların kısaca anlatılan bu davranış modeli taklit edilmeye çalışılmıştır. Bu çerçevede uzmanlardan oluşan bir gruba, daha önce şahit oldukları veya varlığına dair bilgi sahibi oldukları sahtecilik ve suistimal davranış türlerinin nasıl geliştiğini hikâye etmeleri (storyboard) istenmiştir. Bu hikâyeler esas alınarak, yine uzmanların yardımıyla davranışa dâhil olan aktörler ve suistimal veya sahteciliğe konu olan metâlar belirlenebilmekte, bu davranışın gerçekleşmesi sırasında aktörlerin ilgili metâlarla olan ilişkilerinde benzer diğer aktörlere göre anormal değişimi ortaya koyacak öz nitelikler de tespit edilebilmektedir. Bütün bu işlemler her bir sahtecilik ve suistimal davranış için ayrı ayrı yapılmaktadır. Bu arada, aktör ve metâ ilişkisindeki anormalliğe işaret edecek öz nitelikler de farklı türde oluşturulmuştur. Nitekim bir anormal davranış gelişirken, bunun aktör-metâ arasındaki ilişkide oluşturduğu farklılıklar farklı şekilde ortaya çıkabilmektedir. Kimi özniteliklerde ani değişim gözlenirken, kimi özniteliklerdeki değişim yavaş yavaş olmakta, kimisindeki değişim ise ancak tüm yıldaki değişim ele alındığında fark edilebilmektedir. Bu nedenle özniteliklerde dönemlik (aylık), farksal (mevcut ay ile bir önceki ay değerlerinin değişimi) ve kümülatif (tüm yıldaki toplam) değerler üzerindeki değişim incelenmiştir.

Bir hikâye etme çalışmasının nasıl yapıldığını şu şekilde örneklendirebiliriz. Diyelim ki bir eczacı sigortalının kart numarasını ve bir doktorun da reçete yazmak için gerekli olan sicil numarasını (diploma tescil no, vb.) biliyor ve kendi başına reçete tanzim ederek bu ilaçları satmadığı halde satmış gibi sigorta kurumundan parasını talep ediyor olsun. Eczacı, bu davranışı yaparken dikkat çekmemek için yaygın tüketimi olan ağrı kesici ilaç grubunu tercih ediyor ve hatta farklı ticari isimdeki ilaçları kullanıyor olsun. Bu senaryoda bizim aktörlerimiz doktor, eczacı ve sigortalıdır (bir senaryoda hangi aktörlerin yer aldığına karar verilirken, aktörlerin bu

davranışa bilinçli olarak katılıp katılmadıkları değil, bu davranış nedeniyle onların metalarla olan ilişkilerinde bir anormallik oluşup oluşmadığı dikkate alınmaktadır). Aynı senaryodaki metâlar ise ilaçların etken maddeleridir. İlaç etken maddeleri Dünya Sağlık Örgütü (DSÖ) tarafından Anatomical Therapeutic Chemical (ATC) kodları ile temsil edildiğinden, metâ olarak ilacın ticari adı yerine, ATC kodu referans alınabilmektedir. Bu durumda, aktörlerle metâlar arasındaki ilişkide anormalleşecek ve bu davranışı ele verecek öznitelikler için uzmanlar şu tahminlerde bulunabilmektedir:

- Ayrık (farklı) kişi başına düşen reçete sayısı: Bu senaryoda eczacı az sayıda sigortalının (belki sadece bir tane) kart numarası ile reçete tanzim ettiği için eczacının ayrık sigortalı başına düşen reçete sayısı benzer eczanelere göre farklılık göstermeye başlayacaktır. Burada öznitelik türü dönemsel olarak seçilebilir.
- Ayrık doktor başına düşen reçete sayısı: Benzer şekilde eczacı, az sayıda doktorun sicil numarasını kullandığı için, reçete sayısı arttığı halde, ayrık doktor sayısında aynı oranda artış olmayacaktır. Bu da ayrık doktor başına reçete sayısı oranında bir anomaliye neden olacaktır. Bu öznitelik de dönemsel olarak kullanılabilir.
- Toplam reçete sayısı: Eğer eczacı bu davranışı çok kısa bir süre yapar ve bu süre içerisinde çok sayıda reçete tanzim ederse, bu durumda eczacının kendisinin daha önceki toplam reçete sayısında ciddi bir yükseliş olacaktır. Bu yükseliş, kendisine benzeyen diğer eczacılardan daha fazla olduğunda anormal bir durum olduğuna işaret ediyor olabilecektir. Bu nedenle bu öznitelik türü farksal olarak seçilebilir.

Diğer aktörlerin nitelikleri de benzer şekilde, senaryoya uygun gerekçelerle seçilir ve öznitelik için uygun tür (dönemsel, farksal, kümülatif) belirlenir. Diğer taraftan bu işlem, her bir sahtecilik ve suistimal davranış senaryosu için tekrarlanır ve hepsi için uygun aktörler, metâlar ve ilgili senaryo gerçekleştiğinde anormal hale gelecek aktör-metâ ilişkisini temsil eden öznitelikler uygun türlerde belirlenir.

4.2. Aktör ve Niteliklerin Ağırlıklandırılması

Buraya kadar seçimi yapılan aktör, meta ve öznitelikler, risk hesaplaması yaparken kullanacağımız temel parametrelerdir. Ancak en az bu kadar önemli olan

diğer bir husus da bu parametrelerin hesaplamadaki ağırlıklarının nasıl olacağıdır. Problemimizin bir sınıflama problemi olduğu dikkate alındığında, elimizdeki niteliklerin sonuçla olan korelasyonunun sınıflamanın başarısı için önemi daha iyi anlaşılacaktır. Ayrıca aynı aktör ve niteliklerin farklı alt kümelerinin farklı anormal davranışların tespitinde kullanılabilir olması, doğru ağırlıklandırma yapamazsak kullandığımız aktör, meta ve öznel kümelerinin bir provizyon talebini aynı anda farklı anormal davranışlar için riskli bulma olasılığını da artırmaktadır. Bu nedenle iyi bir sınıflama için başlangıç ağırlıklar oldukça önemlidir. Bunun için iki farklı ağırlık metriği kullanılmıştır. Bunlardan ilki her bir anormal davranış (l) için aktörün (b) ağırlığını temsil eden (w^b_l) değeridir. Diğer bir ağırlık ise, yine her bir anormal davranış (l) için, aktörlerin metalarla olan ilişkisini temsil eden öznel niteliklerin ağırlıklarıdır (s^l_m).

Aktör ve öznel niteliklerin ağırlıkları, uzmanlar tarafından öznel (sübjektif) olarak belirlenmek durumundadır. Ancak birden fazla uzmanın kendi tecrübelerine göre ortaya koyacağı nesnel yaklaşımların tek ve ortak bir karara dönüşmesi için nesnel bir yöntem kullanmak durumundayız. Bir grup uzmanın karar üretmesi için kullanılan yaygın yöntemler arasında Delphi yöntemi [40], Rank Order Centroid (ROC) [41], Ratio yöntemi [42] ve ikilik düzende çiftleri karşılaştırma (binary pairwise comparison) [38] yaygın kullanılan yöntemlerdir. Delphi yönteminin uygulanması için karar verecek komisyon için bir direktör atanmalıdır. Direktör, üyelere yöneltilecek soruları hazırlar ve üyelere yöneltir. Direktörü üyelerle serbest şekilde iletişim kurabilirken, panel üyeleri birbirlerinin kimliklerini bilmezler, kendi aralarında iletişim kuramazlar ve sadece kendilerine yöneltilen sorulara iteratif şekilde cevaplar verirler. Direktör, her iterasyon sonunda elde ettiği bilgileri filtreler ve toparlar ve üyelere paylaşır. Her üye, diğer üyelerin görüşlerini görür ve dilerse bu görüşlere aykırı görüş yazabilir veya bu görüş doğrultusunda kendi düşüncesinde değişiklik yapabilir. İterasyonlar, konu üzerinde mutabakat sağlanana kadar devam eder. Delphi yöntemi, ağırlıklandırma dışında, mutabakat sağlanması amaçlanan tüm karar problemleri için kullanılabilen bir yöntemdir. Bununla birlikte, diğer yöntemlere göre daha fazla zaman ve insan kaynağı gerektiriyor olması, bu yöntemin faydası ve kullanılması konusunda direktör ve üyelerin ikna etmek konusunda önemli bir zorluktur [40].

ROC yönteminde ise ağırlıklar, niteliklerin mertebesi (rank) esas alınarak kolay bir şekilde hesaplanır. Bu yaklaşım, karar vericilerin, bir şeyin ne kadar değerli

olduđuna dair bir puanlama yapmasının, o Őeyin ađırlıđını belirlemelerinden daha kolay olduđu tespitine dayalıdır. Ađırlıklar, $W_i = \left(\frac{1}{M}\right) \sum_{n=i}^M \frac{1}{n}$ formülü ile hesaplanır. Burada M, nitelik sayısını, W_i ise *i* indisli elemanın ađırlıđını temsil etmektedir. Bu durumda örneđin M=5 için ađırlık dađılımını 0.46, 0.26, 0.16, 0.09, 0.03 Őeklinde olacaktır. Hesaplama oldukça basit olmasına rađmen, bu yöntemde ađırlık deđerleri oldukça dađınık olmaktadır ve herhangi iki eleman aynı ađırlıđa sahip olamamaktadır [41].

Diđer bir yöntem olan Ratio yöntemi ise ROC ile benzer Őekilde rank temelli bir hesaplama kullanır. Buna göre karar verici niteliklere 10 ile 100 arasında ve 10'un katları olacak Őekilde mertebe ataması yapar. Daha sonra atanan deđerler normalize edilir ve nihai ađırlıklar elde edilir. Bu yöntemde de basit bir hesaplama olmasına rađmen, herhangi iki deđerin aynı ađırlıđa sahip olması söz konusu olmamaktadır [42].

Önerilen çalıřmada EMÖ tabanlı bir yaklařım esas alındıđı için, ađırlıkların oluřturulması konusunda da uzmanların deđerlendirmeleri dikkate alınarak ilerlenmiřtir. Ancak farklı uzmanlar tarafından verilecek ađırlıkların tek bir ađırlık deđerine indirgenebilmesi için bir analitik hiyerarřik iřleme (analytical hierarchy process - AHP) [38] yöntemi olan ikilik düzende çiftleri karřılařtırma (binary pairwise comparison) yöntemi kullanılmıřtır. Böylelikle analitik bir yöntemle farklı düzeyde tecrübesi olan uzmanların ortak tecrübesinin tek bir deđere indirgenmesi sađlanabilmiřtir. Bu iřlem sırasında uzmanlara aktör-aktör ve öznitelik-öznitelik eřlemesinin yapılacađı iki ayrı matris verildi. Her bir uzmanın bađımsız olarak hangi aktörlerin ve niteliklerin ikiřer ikiřer eřleřtiklerinde daha önemli olanı seřmeleri istendi. Bu iřlem, her bir sahtecilik türü için tekrarlandı. Sonra belirlenen ađırlıklar standardize edilerek aktör ve niteliklere paylařtırıldı. Klasik makine öđrenmesi süreçlerinde olduđu gibi uzmanlardan sadece bařlangıç olarak nitelik seřimi ve ađırlıklandırma yapmaları istenmekle yetinilmemiř, bu aktör, meta, öznitelik ve ađırlıklarla elde edilen sonuçları yine uzmanların deđerlendirmeleri istendikten sonra, aynı uzmanlardan kendilerini tatmin edecek sonuçlar elde edebilene kadar öznitelik ve ađırlıklarda deđiřiklik yapabilmelerine imkân tanınmıřtır [2], [5]. Bu yöntem uygulanırken iki problemle karřılařılmıřtır:

- i) Ağırlıklandırma için yapılan her iterasyon sonunda uzmanların aynı ağırlık değerleri konusundaki mutabakatının sağlanması.
- ii) İterasyon sonunda yapılan doğruluk ölçümü sonrasında, yeni bir iterasyona daha ihtiyaç kalıp kalmadığına karar verilmesi.

Bir grup karar vericinin mutabakat sağlanması, literatürde iyi tanımlanmış bir problemdir. Mutabakat, bir grup tarafından beklentinin en çok karşılandığına inanılan tek bir karar üzerinde mutabakat sağlanması ve kararı desteklemesi şeklinde tanımlanmaktadır [43]. Bu problem içindeki ilk mesele, uzmanların kendi görüşlerinin nasıl (sayı, ifade, vb.) temsil edileceğidir. Yöntemlere baktığımızda görüşlerin, uzmanların tercihiye göre, sayı, ifade veya ifade-sayı şeklinde temsil edilebildiği görülmektedir [44]. İkinci mesele ise, özellikle görüşlerin ifade ile temsil edildiği durumlar için olmak üzere, her bir grup üyesinin görüşünün mutabakat ifadesine olan uzaklığının ölçülmesi suretiyle sağlanan görüş birliğinin mutabakat mertebesinin belirlenmesidir [44]. Yakın zamanda yapılan bir çalışmada [43], grup mutabakat mertebesini artırmak için görüşlerin temsil edilmesinde kullanılan ifadelerin daha granül şekilde kullanılmasına dayalı bir model önerilmiştir. Başka bir çalışmada ise, grup üyelerinin kendi görüşleri ile çelişkili görüşler ileri sürme potansiyeli nedeniyle bir çelişki seviyesinin ölçülmesi, bu problemin bir başka meselesi haline gelmiştir ve bazı çalışmalarda da bu ölçüt kullanılmıştır [45]. Çelişki seviyesi ile ilgili ölçütlerin belirlenmesinde de iki temel yaklaşım esas alınmaktadır. Birincisinde uzmanların ilk görüşleri esas alınırken, ikincisinde uzmanların değişen görüşleri esas alınarak çelişki düzeyi ölçülmektedir [46].

Bütün bu çalışmalar ile daha önce bahsedilen Delphi [40], ROC [41] ve Ratio [42] yöntemleri bir grup karar vericinin ortak bir karara ulaşması için farklı modeller önermektedir. Bizim çalışmamızda ise, her bir serideki aktör ve niteliklerin belirlenmesi için uzmanlar arasında bir odak grup çalışması [47] yapılmıştır. Ardından her bir uzmandan, aktör ve niteliklerin ağırlıklarını ikilik düzende çiftleri karşılaştırma (pairwise comparison method) yöntemi [38] ile belirlemesi istendi. Belirlenen ağırlıklar sayısal değerler olduğu için, uzmanların belirlediği ağırlıkların ortalaması, grubun geçici mutabakatı olarak kabul edilmesi, zaman ve kaynak kısıtı nedeniyle daha uygun görüldü. Belirlenen aktör-nitelik kümesi ve mutabık kalınan ağırlıklarla yapılacak çalışmanın doğruluğu, ancak eFAD tarafından bu serinin kullanılmasıyla mümkün olmaktadır. Bu çalışmamızda EMÖ yaklaşımı benimsendiği

için uzmanlar, eFAD tarafından risk hesaplamasında esas alınan serilerin sonuçları tekrar uzmanlara gösterilmiş ve sadece belirlenen ağırlıkların değil, gerekli görülürse aktör ve niteliklerin de değiştirilmesi imkânı sağlanmıştır.

Karşılaştığımız ikinci problem konusu ise, bu yeni bir iterasyona daha ihtiyaç olup olmadığına karar vermektir. Bunun için modelin ve serinin belirli bir doğruluk, AUC, vb. değerine ulaşması hedef alınabilirdi. Ancak bu durumda daha sezgisel bir yaklaşımla ilerlemek durumunda kalınırdı. Bu tür sistemlerin nihai amacı, maliyet etkin bir şekilde sahtecilik ve suistimal vakalarının tespit edilmesi olduğundan, biz de sistemin maliyet etkinliğine dair bir model kullanarak, sistemin makul ölçüde maliyet etkin olduğunu görene kadar iterasyonları devam ettirdi. Maliyet etkinlikle ilgili modelin detayları sonraki bölümlerde açıklanmaktadır.

4.3. İki Aşamalı Veri Ambarı

Literatürdeki çalışmalarda proaktif çözümlerin yok denecek kadar az olmasının en önemli nedeni performans problemidir. Geliştirilen modelimizde, bu darboğazın aşılması için iki aşamalı bir veri ambarı tasarlanmıştır. Bu veri ambarının ilk aşaması klasik yıldız şema yapısında bir veri ambarıdır ve operasyonel veri tabanındaki veriler bazı veri temizleme algoritmaları ve ETL (extract, transform, load) prosedürleri kullanılarak buraya taşınır. Veri ambarının ikinci bileşeni ise, risk hesaplama motorunun kullanımına hazır olacak şekilde aktörlerle meta türleri arasındaki tüm olası niteliklerin dönemsel, farksal ve kümülatif değerleri yer almaktadır.

Aktörlerle metâlar arasındaki bu öznelik değerleri, $(T_m^b)_{ij}$, sadece ilgili niteliklerin nominal değerleri olmayıp, ilgili aktörlerin kendilerine benzer olan diğer aktörlerin bu değerlerine göre normalden uzaklıklarının ölçüsü olmak üzere z-skor değerleri şeklinde hesaplanmaktadır. Böylelikle risk motorunun yaptığı hesaplamada, her bir aktörün ilgili metâ ile olan ilişkisi açısından kendisine benzer olan aktör kümesinden ilgili niteliği açısından ne kadar farklılaştığı ölçümlenebilmektedir. Aktörlerin kendilerine benzer olan aktörlerle birlikte değerlendiriliyor olmaları, bu modeldeki en önemli noktalardan birisidir. Bunun için işleme başlamadan önce eldeki aktörler veri madenciliği yöntemleri arasında yer alan kümeleme (clustering) yöntemlerinden biri olan Beklenti Çoklama-BÇ (Expectation Maximisation-EM) yöntemi ile kümelere ayrılmıştır. Her bir aktörün niteliği, kendi içinde olduğu aktör

kümesinin ilgili niteliği referans alınarak hesaplanmıştır. Son olarak, risk hesaplamasında elde edilecek risklerin nominal değerlerinin birbirleri ile sağlıklı karşılaştırılabilmesi için tüm z-skor değerleri 1-100 değerleri arasında normalize edilmiştir.

Geliştirilen veri ambarının ikinci aşamasında, olası tüm sahtecilik ve suistimal davranışların tespitinde kullanılmak üzere uzmanlar toplam 138 nitelik için ön hesaplama yapılmaktadır. Tablo 4.1’de bu niteliklerin metâ türlerine göre dağılımı gösterilmektedir. Dolayısıyla tanımı yapılacak yeni bir sahtecilik veya suistimal davranışı için şayet bu kümedeki seçenekler yeterli ise, yapısal herhangi bir değişikliğe gerek olmadan sistem adapte olabilmektedir. Ancak yeni bir niteliğe ihtiyaç duyulması halinde sadece bu özneliğe özel olacak şekilde veri ambarında güncelleme yapılması yeterli olacaktır.

Tablo 4.1: Deneyde kullanılan niteliklerin sayısı ve türü.

Aktör	Metâ			
	Genel	ATC Kodu	İlaç Firması	Teminat Türü
Eczacı	7	7	7	
Doktor	17	7	7	
Sigortalı	29	7	7	5
Hastane	33			5

4.4. Risk Değerlendirme Motoru

Risk Değerlendirme Motoru (RDM), eFAD’ın üçüncü bileşenidir ve görevi provizyon talebi yapıldığında ilgili provizyonun daha önce tanımlanmış tüm anormal davranışlar açısından riskini hesaplamaktır. Her bir anormal davranış (F_l) için, *parametre serisi* adı verilen ve içerisinde aktörlerin (A_i^b), metâların (C_j), özneliklerin (T_m^b)_{ij}, aktörlerin ağırlıklarının (w_i^b), ve özneliklerin ağırlıklarının (S_m^l) yer aldığı parametre kümeleri eFAD’ın Yönetim Paneli üzerinden tanımlanabilmektedirler. IML yaklaşımı ile de uygun olarak ihtiyaca göre mevcut seriler üzerinde değişiklik yapılabileceği gibi, yeni anormal davranışlar için seri tanımlamaları da yapılabilmektedir.

RDM’nin hesap yapabilmesi için bir provizyon veri setinin ona bildirilmesi yeterlidir. Dolayısıyla proaktif risk hesaplaması yapabilmektedir. Ancak istenirse, daha önce gerçekleşmiş bir dizi provizyon talebi de RDM’ye girdi olarak verilebilir.

RDM'nin her durumda yaptığı işlem aynıdır. Öncelikle provizyonda yer alan her bir aktörün risk değeri aktörlerin metalarla olan ilişkilerinde benzer aktörlere göre normalden ne kadar uzak olduklarına göre hesaplanır (Denklem 4.1). Ardından da provizyondaki aktörlerin riskleri, bir toplam fonksiyonu ile toplanarak provizyonun risk değeri hesaplanır (Denklem 4.2). Bir provizyonda birden fazla metâ olabilir. Örneğin bir reçetede birden fazla ilaç yer alabilir. Bu durumda aktör-metâ arasındaki ilişki için hesaplanan değerler arasında maksimum olanı seçilir ve hesaplama dâhil edilir. Risk hesaplaması için verilen denklemlerin daha iyi anlaşılabilmesi için ilgili notasyonun açıklamaları aşağıda belirtilmektedir:

- Notasyon:

- MC_k , k'inci provizyon talebini ifade eder.
- (A_i^b) , b aktör tipindeki i'inci aktörü ifade eder. Aslında i indisi, i(b, k) şeklindedir ve k'inci provizyon talebindeki i'inci aktörü ifade eder.
- C_j , j'inci metâyı ifade eder.
- F_l , l'inci anormal davranış türünü ifade eder.
- $(T_m^b)_{ij}$, b aktör tipindeki i'inci aktör ile j'inci metâ arasındaki m'inci özniteliğin z-skor değerini ifade eder.
- s_m^l , l'inci anormal davranış türü için m'inci özniteliğin ağırlığını ifade eder.
- w_l^b , l'inci anormal davranış türü için b aktör tipi için ağırlığı ifade eder.
- $G^l(A_i^b)$, b tipindeki i'inci aktörün l anormal davranış türü için risk değerini ifade eder.
- R_k^l , l anormal davranışı için k'inci provizyon talebinin toplam riskini ifade eder.

Denklem 4.1'de bir aktörün toplam riskinin nasıl hesaplandığı gösterilmektedir.

$$G^l(A_i^b) = \sum_{m=1}^{M_k} \max_j (s_m^l * (T_m^b)_{ij}) \quad (4.1)$$

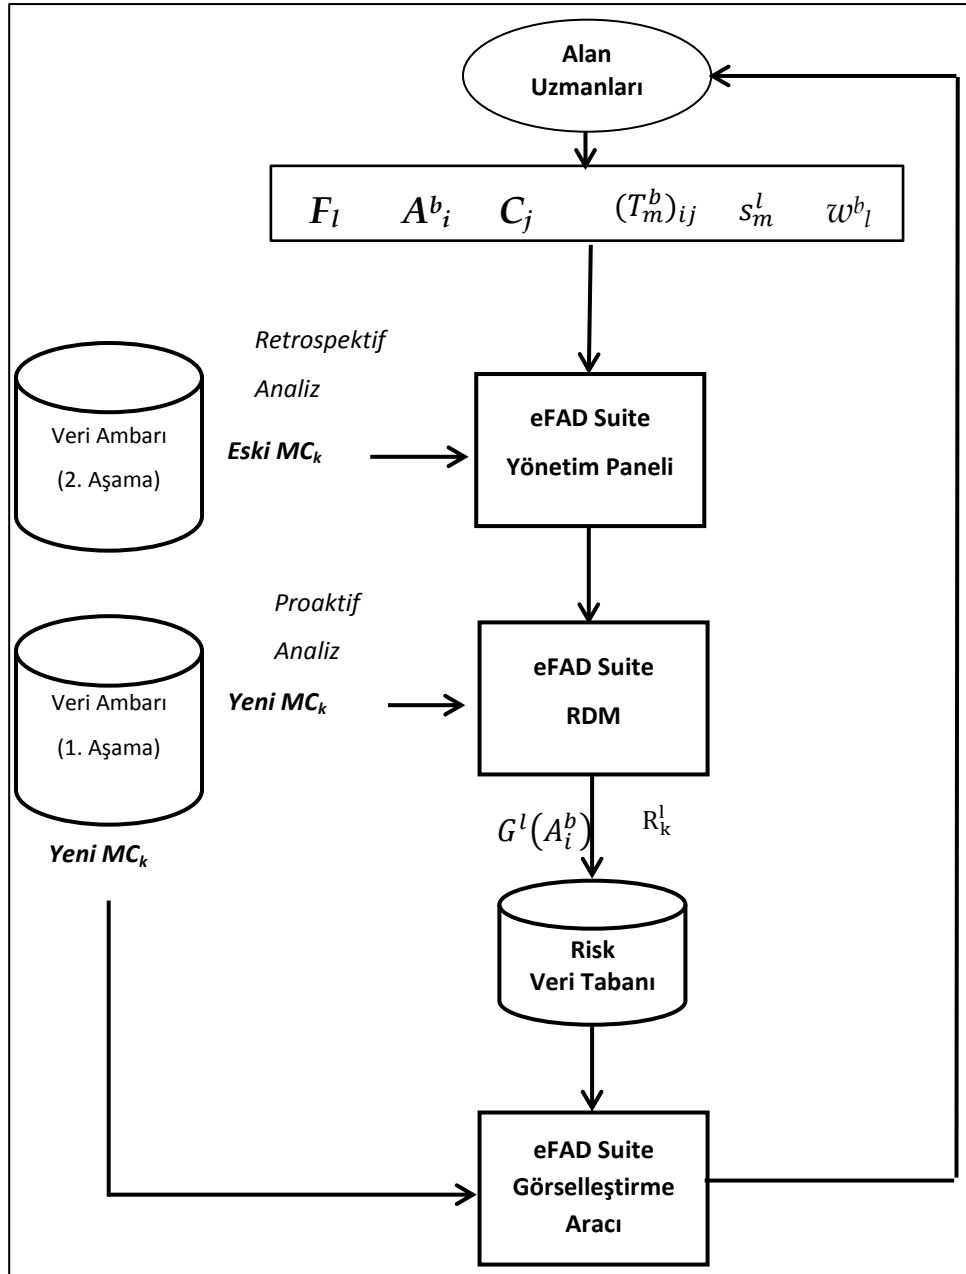
Denklem 4.1'deki yöntemle provizyonda yer alan her bir aktörün riskleri hesaplandıktan sonra Denklem 4.2'de belirtildiği şekilde her bir anormal davranış türü için provizyon talebinin toplam riskleri hesaplanır.

$$R_k^l = \sum_{b=1}^{\#actors} w_l^b * G^l(A_i^b) \quad (4.2)$$

4.5. Görselleştirme Aracı

eFAD uygulamasının dördüncü ve son bileşeni olan görselleştirme aracı eFAD tarafından hesaplanan risk değerlerinin sağlık ve sigortacılık konusunda uzman kullanıcılar tarafından değerlendirilmesi ve hesaplamanın dayanaklarının gösterilmesi amacıyla kullanılmaktadır. Bu araç, farklı perspektiflerden sunduğu analizler sayesinde uzmanların aktörler arasındaki ilişkileri, aktör-metâ arasındaki ilişkilerde ortaya çıkan farklılıkları gözlemlemelerine ve bu anormal davranışların ortaya çıktığı dönemleri doğrudan öne çıkartarak uzmanların o döneme ait daha detaylı analiz yapmalarına olanak sağlamaktadır. Bu yönüyle bir çeşit delillendirme fonksiyonu da görmektedir. Bir yandan da uzmanların bu analiz sırasında yeni sahtecilik türleri yakalamaları veya daha önce bildikleri sahtecilik davranışlarının karakteristiği ile ilgili daha derin bir bilgi sahibi olmaları da mümkün olabilmektedir. Bu sayede IML yaklaşımı sayesinde bir sonraki öğrenme iterasyonunda sisteme tanımlanacak davranışlar, aktör, meta ve ağırlıklarla ilgili daha isabetli önermelerde bulunabilmeleri mümkün olmaktadır. eFAD sisteminde görselleştirme aracı olarak Qlikview Business Intelligence™ platformu kullanılmıştır. Şekil 4.3, alan uzmanlarının sistemin girdileri ve çıktıları ile nasıl etkileşim içinde olduğunu göstermektedir.

Görselleştirme aracında iki temel modül bulunmaktadır. Bunlar sırasıyla proaktif analiz ve reaktif analiz modülleridir. Proaktif ve reaktif analiz modülleri üçer aşamadan oluşmaktadır. Her ikisinde de öncelikle provizyonların risk değerleri gösterilmekte, ikinci aşamada, seçimi yapılan provizyon(ların) aktörlerinin öznitelikleri açısından diğer aktörlere göre nasıl değişim geçirdikleri gösterilmekte, son olarak da seçilen aktörlerin seçilen tarihlerdeki provizyonlarının detayları gösterilmektedir. Böylelikle sağlık ve sigortacılık alanındaki uzmanlar, bu işlemlerin sağlık ve sigortacılık açısından uygunluğunu değerlendirerek ilk seçimi yapılan işlemin bir anormal davranışın parçası olup olmadığına kanaat getirebilmektedirler.

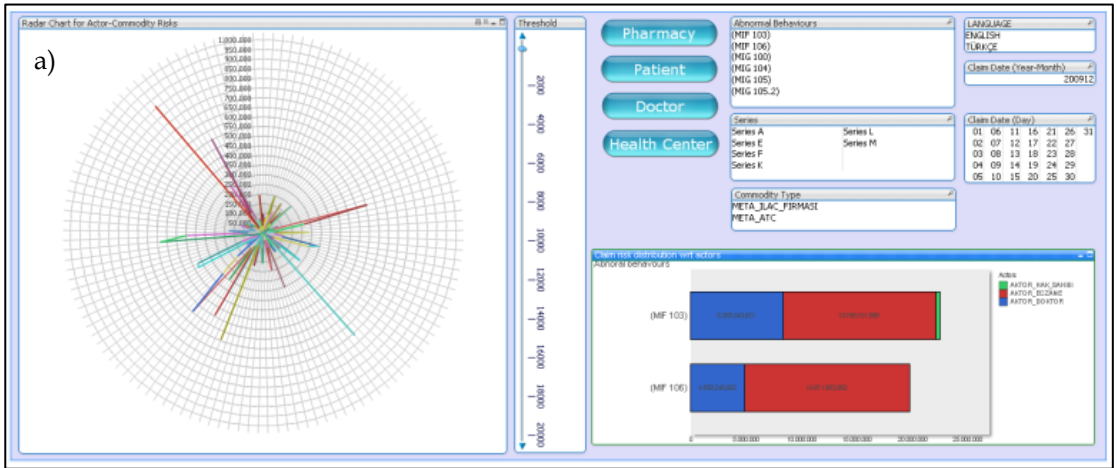


Şekil 4.3 Alan uzmanlarının sistemin girdi ve çıktıları ile etkileşimi.

Şekil 4.4, bu üç aşamanın proaktif analiz modülünde nasıl olduğunu göstermektedir. Buna göre Şekil 4.4.a)'daki radar grafikte provizyonların risk değerleri gösterilmektedir. Grafikteki çubukların uzunluğu risk büyüklüğünü temsil etmektedir. Bu sayede uzman doğrudan riski yüksek provizyonu ayırt edip seçebilmektedir. Sonra Şekil 4.4.b)'de de görüleceği üzere seçilen provizyondaki aktörlerin, ilgili anormal davranış türü için hesaplamada kullanılan öz niteliklerinin o aktör ile aynı kümede olan diğer aktörlerin öz nitelikleri ile karşılaştırması gösterilmektedir. Burada bu öz nitelik değerlerinin aslında normalize edilmiş z-skor değerleri olduğunu hatırlamak gerekir. Grafikte aktörün ilgili öz nitelik değerinin yanı

sıra, aktörün ait olduğu kümedeki aktörlerin ilgili öznelik açısından ortalama değeri ve bu ortalamanın +/- standart sapma eğrileri de gösterilmektedir. Böylelikle uzman, aktörlerin hangi öznelik açısından tarih aralıklarında kendi kümelerinin ne kadar uzağına çıktıklarını doğrudan görebilmekte ve incelemek istediği tarih aralığını seçerek Şekil 4.4.c)'de görüleceği üzere provizyonların detaylarını görüntüleyip sağlık ve sigortacılık açısından değerlendirmesini yaparak nihai kanaatini verebilmektedir.

Yukarıda belirtildiği üzere görselleştirme aracının reaktif modülü de üç aşamadan oluşmaktadır. İlk aşaması Şekil 4.4.d)'de gösterilmektedir. Burada hangi anormal davranış açısından hangi tarihlerde kaç tane anormal davranış tespit edildiği, bu davranışların aktörlere göre dağılımı, vb. bilgiler gösterilmektedir. Uzmanın yapacağı tek şey, burada dikkatini çeken aktör veya davranış türünü seçmektir. Diğer iki aşama, reaktif modüldeki ile aynıdır ve üç aşama sonunda uzmanın kanaat getirmesi mümkün olabilmektedir.



Şekil 4.4: eFAD Suite – Proaktif ve reaktif modüllerine ait ekran görüntüleri.
a) Proaktif modül radar çizge ekranı. b) Aktör-metâ ilişkisinde anomali tespiti.
c) Aktörlerin işlem detayları. d) Reaktif modülde riskli aktörlerin analizi.



Şekil 4.4: Devam.

5. SONUÇLAR

eFAD Sisteminin doğruluğunun ölçülmesi için gerçek provizyon verilerinin kullanıldığı deneysel bir çalışma yapılmıştır. Veriler, Türkiye’de özel sağlık sigorta sektöründe yaklaşık 100.000 sigortalısı olan ve en büyük sigorta şirketlerinden birisi olan Şirket A’ya aittir (gizlilik kuralları gereği şirketin ismini veremiyoruz). Referans alınan veri tabanında 2008-2011 yılları arasında 845.247 adet reçete provizyon verisi mevcuttur.

Hatırlanacağı üzere, anormal davranışlarla ilgili seriler (aktör, meta, öznelik ve ağırlıklar kümesi) daha önce uzmanlar tarafından eFAD Yönetim Paneli kullanılarak yapılmaktaydı ve deneysel çalışma için, toplam 6 adet anormal davranış tanımı yapılmıştır. Daha sonra Yönetim paneli üzerinden bu 845.247 adet provizyonun bu 6 farklı anormal davranış türüne göre risk hesaplamaları yapılmıştır. Hesaplanan risk değerleri nominal değerler olduğu için, ilgili provizyonun riskli olup olmadığı belirlenebilmesi için bir eşik değer tespit edilmesi gereklidir. Bu çalışmada eşik değer olarak her bir anormal davranış için hesaplanan risklerin ortalamasına 1 standart sapma değeri eklenerek belirlenmiş ve bu eşik değer üstünde olan provizyon talepleri, eFAD tarafından riskli olarak sınıflanmıştır. Ardından, eFAD’ın başarısının ölçülmesi için toplamda 288 adet olmak üzere her bir anormal davranış türü için 48’er tane provizyon talebi rastgele şekilde seçilmiş ve uzmanların değerlendirmesine sunulmuştur. Uzmanlardan, eFAD tarafından hesaplanan risk değerinden habersiz olarak (Şekil 4.4.a’deki grafikleri görmeksizin) sadece işlemlerin numaralarını görüp seçerek delillendirme aşamalarını incelemeleri (Şekil 4.4.b ve c) ve ilgili provizyonun anormal bir davranışın parçası olup olmadığına, başka bir deyişle bu provizyonun riskli bulunup incelenmeye gerek olup olmadığına karar vermeleri istenmiştir. Uzmanların görüşü “gerçek”, eFAD’ın önerisi ise “tahmin” olarak set edilip doğruluk tablosu oluşturulmuştur.

eFAD, IML yaklaşımı ile geliştirildiği için uzmanların deneyin sonunda doğruluk tabloları oluştuktan sonra, Yönetim Paneli üzerinden daha önce tanımlanan seriler üzerinde değişiklik yapmalarına imkân tanınmış ve deney tekrarlanmıştır. Bu iterasyonlar, artık eFAD’ın tanımlı olan anormal davranışları tespit konusundaki doğruluk değerinde anlamlı bir iyileşme olmadığı gözlemleninceye kadar tekrar edilmiştir.

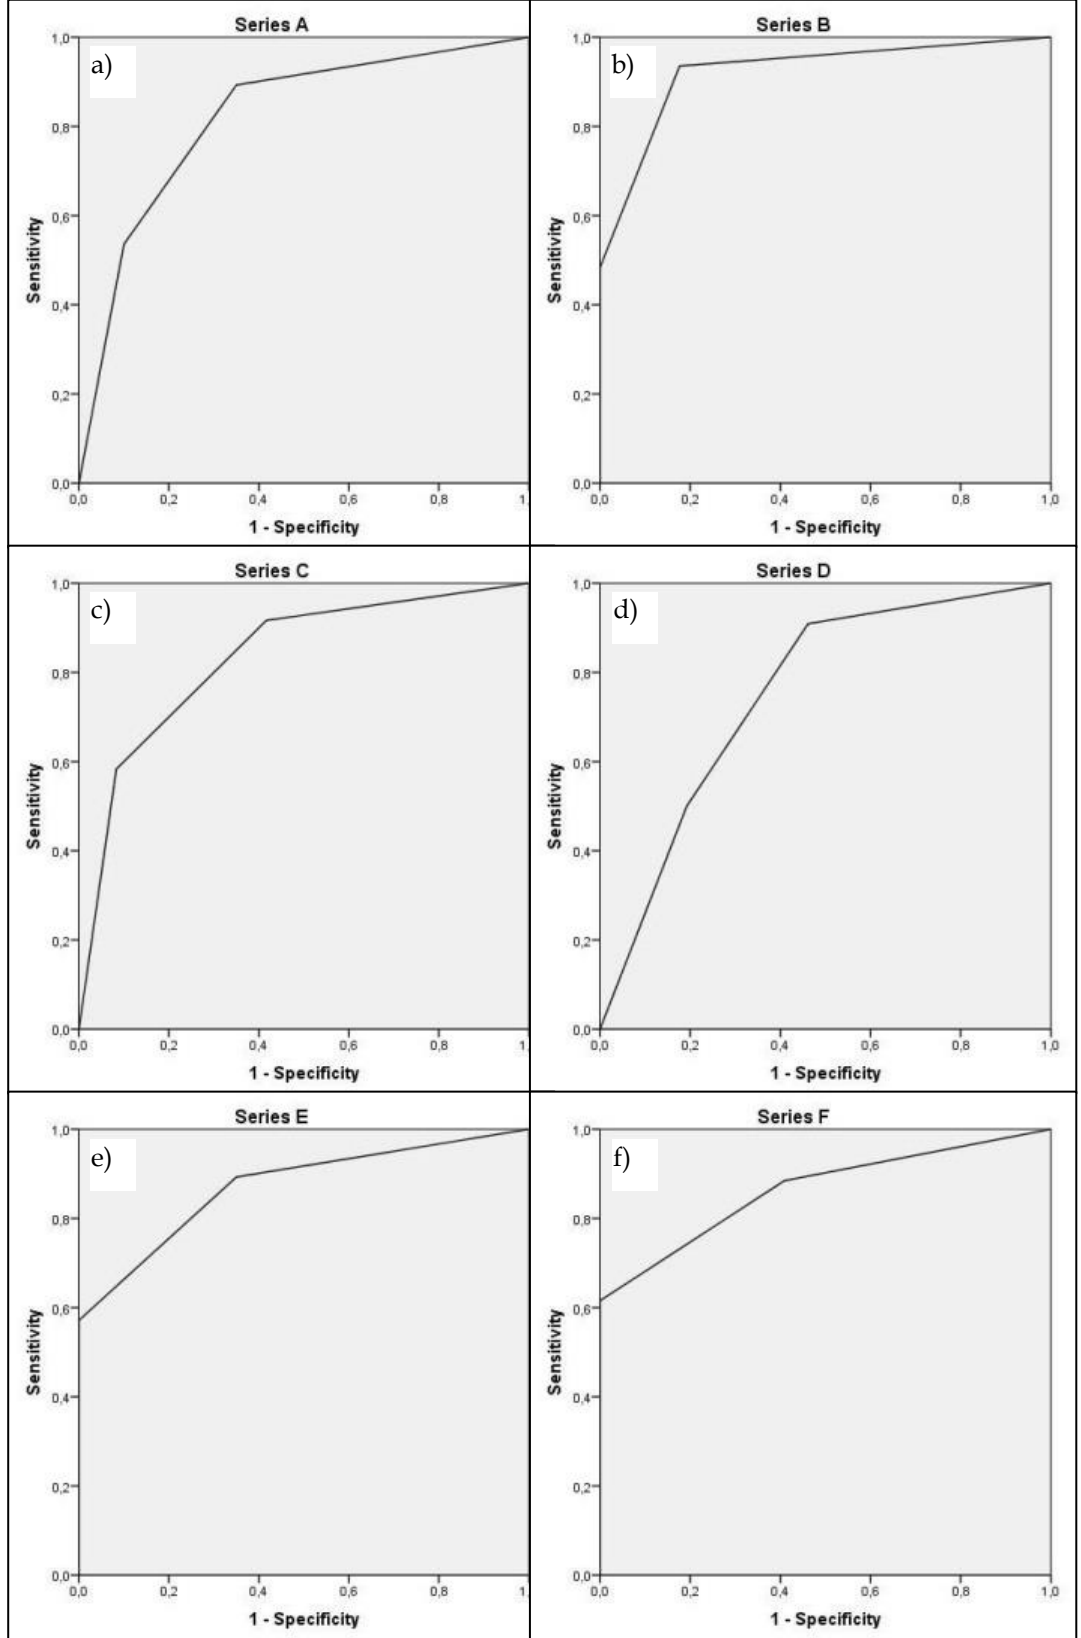
5.1. Doğruluk Modeli

Uzmanların tespitlerinin gerçek (actual) durum kabul edildiğinde ve eşik değerinin ortalama + bir standart sapma alındığı eFAD'ın öngörüsünün de tahmin (prediction) olarak kabul edildiğinde ortaya çıkan sonuçlar Tablo 5.1'de gösterilmektedir. Tablodaki doğru pozitif (DP), doğru negatif (DN), yanlış pozitif (YP) ve yanlış negatif (YN) değerlerinden yola çıkarak doğruluk (accuracy) değerleri hesaplanmıştır.

Tablo 5.1 daha detaylı incelendiğinde DP değerlerinin %88,5 ile %93,5 arasında değiştiğini ve sistemin hassasiyet (sensitivity) derecesinin oldukça yüksek olduğunu görmekteyiz. Benzer şekilde sistemin DN değeri de %53,8 ile %82,4 arasında değiştiğinden, eFAD'ın yüksek bir kesinliğe (specificity) sahip olduğunu söyleyebiliriz. Sonuç olarak sistemin genel doğruluk (accuracy) oranı %70,9 ile %89,6 arasında değişmektedir. eFAD'da olduğu gibi, bir eşik değeri üzerinden sınıflama yapan sistemlerde doğruluk (accuracy) oranı farklı eşik değerler için değişebilmektedir. Optimal eşik değerinin bulunup bulunmadığı da farklı testlerle ancak ayırt edilebilmektedir. Bu nedenle sistemlerin başarısının ölçülmesi için Şekil 5.1'de görüleceği üzere ROC eğrilerinin çizilmiş ve bu eğrilerin altında kalan alanlar ölçülmüştür. Bu çerçevede eFAD'ın AUC değerleri yine Tablo 5.1'de görüleceği üzere %75,2 ile %92,2 arasında değişmektedir.

Tablo 5.1: Deneysel analizin doğruluk ve AUC değerleri.

Anormal Davranış	Tahmin	Gerçek		Doğruluk	AUC
		Pozitif	Negatif		
A	Pozitif	89.3%	35.0%	79.2%	82.1%
	Negatif	10.7%	65.0%		
B	Pozitif	93.5%	17.6%	89,6%	92.2%
	Negatif	6.5%	82.4%		
C	Pozitif	91.7%	41.7%	75.00%	83.3%
	Negatif	8.3%	58.3%		
D	Pozitif	90.9%	46.2%	70.80%	75.2%
	Negatif	9.1%	53.8%		
E	Pozitif	89.3%	35.0%	79.20%	87.1%
	Negatif	10.7%	65.0%		
F	Pozitif	88.5%	40.9%	75.00%	86.4%
	Negatif	11.5%	59.1%		



Şekil 5.1: Deneysel analizin ROC değerleri. a) A Serisinin ROC eğrisi. b) B Serisinin ROC eğrisi. c) C Serisinin ROC eğrisi. d) D Serisinin ROC eğrisi. e) E Serisinin ROC eğrisi. F) F Serisinin ROC eğrisi

5.2. Maliyet Etkinlik Modeli

Hatırlanacağı üzere ABD'deki National Health Care Anti-Fraud Association (1991) derneğinin raporunda [18], sağlık sigortacılığı alanındaki sahtecilik ve suistimal oranını %10 olarak tahmin edildiği belirtilmişti. Dolayısıyla bunu önlemek için hiçbir aksiyon alınmamasının zararı, toplam maliyetin %10'u kadar olacaktır. Bu durumda, sadece bu %10'luk dilimdeki vakaları yakalamak için kullanılacak aracın hem başarısı yeterince yüksek, hem de bu aracı kullanacak uzmanların harcadıkları zaman maliyetinin olabildiğince düşük olması gereklidir.

Maliyet etkinlik hesaplamalarında dikkate alınacak diğer bir konu da bu tür karmaşık problemlerdeki sınıflayıcıların %100 doğruluk oranına ulaşmasının çok zor olduğudur. Bilindiği üzere doğruluk tablosu yaklaşımında bir sistemin iki türlü uç durumunun olduğudur. Birincisinde sistemin he provizyona normal dediği ve gerçekte de tüm provizyonların normal olduğu; ikincisinde ise sistemin tüm provizyonlara şüpheli dediği ve gerçekte de böyle olduğu düşünülebilir. Her iki durumda da sırasıyla DP ve DN değerleri %100 olur. Ancak gerçek hayatta karşılaşacağımız durumlar bu iki uç noktanın arasında bir yerlerdedir.

Maliyet etkinlik (cost savings) sistemlerin faydalılığını ölçmek için kullanılan bir göstergedir. Çalışmamızda eFAD'ın maliyet etkinliğinin ölçülebilmesi için sistemin tüm çıktılarının (DP, DN, YP, YN) maliyetlerini ve getirilerini dikkate alan ve Phua ve arkadaşları tarafından geliştirilen model kullanılmıştır [48]. Bu modele göre sistemin her bir çıktılarının maliyetleri Tablo 5.2'de gösterilmektedir.

Tablo 5.2: Deneysel analizin maliyet etkinlik hesap yöntemi.

Maliyet kalemi	Hesaplama yöntemi
DP Maliyeti	DP sayısı * İnceleme başına ortalama maliyet
DN Maliyeti	DN sayısı * Ortalama provizyon maliyeti
YP Maliyeti	YP sayısı * (İnceleme başına ortalama maliyet + Ortalama provizyon maliyeti)
YN Maliyeti	YN sayısı * Ortalama provizyon maliyeti

Maliyet etkinlik hesaplanırken, hiçbir aksiyon alınmamasının alternatif maliyeti ile önlem alırken harcadığımız ilave maliyet ve kazandığımız tasarruf

dikkate alınır. Aşağıdaki denklemlerde bu maliyetlerin nasıl hesaplandığı gösterilmektedir:

$$\text{Model Tasarrufu} = \text{Eylemsizlik} - [\text{Maliyet}(\text{TP} + \text{TN} + \text{FP} + \text{FN})] \quad (5.1)$$

$$\text{Tasarruf Oranı} = (\text{Tasarruf Modeli} / \text{En İyi Senaryo Tasarrufu} * 100) \quad (5.2)$$

Bu çalışmamızda tüm Türkiye veya bir bölge ya da ile ait reçeteler üzerinde çalışma yapılmayıp, sadece özel bir sağlık sigorta şirketinin reçete verileri üzerinde çalışılmıştır. Bununla birlikte, elimizde sistemin doğruluğuna dair deneysel bir sonuç olduğundan, bu sonuçlarla eFAD'ın Türkiye veya bir ile ait reçeteler üzerinde kullanılması halinde nasıl bir sonuç doğurabileceğine dair hesaplamalı bir projeksiyon yapmamız mümkündür. Bu doğrultuda, Mollahaliloğlu, Alkan, Dönertaş, Özgülcü, ve Akıcı [49] tarafından ve nüfusu yaklaşık 1 milyon olan Denizli ilindeki reçetelerin maliyetlerine dair yapılan saha çalışması referans alınmıştır. Bu çalışmaya göre Türkiye'deki yıllık toplam reçete sayısı 300 milyon, Denizli ilindeki toplam reçete sayısı ise (nüfusuna projeksiyon yapıldığında) 3.741.046'dır. Yapılan saha çalışmasında tek bir reçetenin ortalama maliyeti ise 133 TL (Çalışmanın yayınlandığı Nisan 2012 itibariyle ~73 USD) olarak tespit edilmiştir. Dolayısıyla eFAD tarafından doğru olarak tespit edilen her anormal reçete için ortalama olarak bu kadarlık bir tasarruf/kazanç sağlanacağı kabul edilebilir. Tablo 5.3, Denizli iline ait verileri göstermektedir.

Tablo 5.3. Denizli iline ait veriler

Toplam Reçete Provizyonu Sayısı	3.741.046
Toplam Reçete Maliyeti	273.096.331 USD
Beklenen Sahtecilik Oranı [19]	10%
Beklenen Sahtecilik Sayısı	374.105
Beklenen Sahtecilik Maliyeti	27.309.633 USD
Normal Provizyonların Sayısı	3.366.941
Normal Provizyonların Maliyeti	245.786.698 USD

Diğer taraftan, uzmanların eFAD tarafından riskli olduğu tahmin edilen her provizyonu incelemek için harcadıkları zamanın da bir maliyeti söz konusudur. Deneyler sırasında harcanan toplam insan gücü, inceleyebildikleri provizyon sayısı

ve bu uzmanların çalıştıkları şirketteki maliyetleri dikkate alındığında, uzmanların eFAD'ın riskli olarak tahmin ettiği her bir provizyon talebi için harcadığı zamanın birim maliyetinin 22 TL (Ocak 2015 itibariyle ~9,5 USD) olduğu hesaplanmıştır. Bunlar da dikkate alınarak eFAD sisteminin maliyet etkinliği, ideal bir sistemin maliyet etkinliği ile karşılaştırmalı olarak Tablo 5.4'te gösterilmektedir.

Tablo 5.4. eFAD sisteminin ideal bir sistemle karşılaştırmalı maliyet etkinliği.

	eFAD	En İyi Senaryo
DP Maliyeti	291.802 USD	374.105 USD
YN Maliyeti	82.303 USD	-
DN Maliyeti	2.727.222 USD	3.366.941 USD
YP Maliyeti	82.303 USD	-
Eylemsizlik Maliyeti	273.096.331 USD	273.096.331 USD
En İyi Senaryo Tasarrufu	261.356.930 USD	249.340.691 USD
Model Tasarrufu	11.739.401 USD	23.755.640 USD
Tasarruf Oranı	4,3%	8,7%

Tablo 5.4'te görüleceği üzere, eFAD sistemi, yaklaşık %10 sahtecilik olduğu varsayılan ve ortalama reçete maliyeti 73 USD olan bir sağlık sigortacılığı ekosisteminde, yine Türkiye ortalama uzman maliyetleriyle kullanıldığında toplam reçete maliyetlerinde %4,3'lük bir tasarruf sağlamaktadır. Bunun maliyete yansımaları ise Denizli için 11,7 milyon USD civarında olmaktadır. Şayet, böyle bir ekosistemde ideal bir sistem tasarlanabilseydi, maliyet etkinlik oranı %8,7 olacak, sağlayacağı tasarruf da 23,7 Milyon USD civarında olacaktır.

5.3. Sonuçların Karşılaştırılması

Tablo 3.1'de, daha önceki çalışmalara dair özet bilgiler sunulmuştu. Tablo 5.5'te ise, daha önceki çalışmalarla bu çalışmamızın doğruluk ve maliyet etkinlik durumları karşılaştırılmaktadır. Hatırlamakta fayda var ki, daha önceki çalışmalar sadece bir aktör veya bir hizmet türüne odaklanarak problemin kısıtlı bir türevi üzerinde çalışmışlardır. Bu açıdan bizim çalışmamız kapsam itibariyle daha geniş olduğu için doğrudan kıyaslamak çok da doğru değildir. Buna ek olarak, bu çalışmaların pek çoğunda doğruluk ve maliyet etkinlikle ilgili ölçümler de yetersizdir. Ne var ki bu alanda yapılan çalışmaların zaten oldukça az olması

nedeniyle, çalışmamızın sonuçlarını karşılaştırabilmek adına Tablo 5.5'te özet bazı bilgiler verilmiştir.

Tablo 5.5'te görüleceği üzere, daha önceki çalışmalardan üç tanesi [30], [31], [35] herhangi bir deneysel çalışma rapor etmemiştir. Bir tanesi ise sadece uzmanların teyit ettiği durumları gösteren bir karşılıklılık matrisi sunmuştur [29]. Diğer üç tanesi [32], [33], [34] ise sadece hassasiyet (sensitivity) ve kesinlik (specificity) değerlerini vermişlerdir. Sadece bir çalışma [36] ise önerilen modelinin AUC değerini ölçmüştür. Yine vurgulamak gerekir ki, bu çalışmaların hiçbiri maliyet etkinlikle ilgili herhangi bir analiz yapmamıştır.

Tablo 5.5: Literatürdeki çalışmaların doğruluk modelleri ve maliyet etkinliklerinin karşılaştırılması.

Çalışma	Doğruluk Modeli	Sonuçlar	Tasarruf Modeli
He vd. (1997)	Doğruluk tablosu	63.60%, 59.87% ve 88.40%.	Yok
Williams (1999)	Deneysel analiz mevcut değil	NA	Yok
Yamanishi vd. (2004)	Deneysel analiz mevcut değil	NA	Yok
Major and Riedinger (2002)	AUC (ROC değerleri verilmiş ve şüpheli tüm işlemlerin gerçek sahtecilik olduğu kabul edilmiş).	66.53%	Yok
Ortega vd. (2006)	DP	73.4%	Yok
	YP	6.9%.	Yok
Yang and Hwang (2006)	Hassaslık (Sensitivity)	64%	Yok
	Kesinlik (Specificity)	67%	Yok
Sokol vd. (2001)	Deneysel analiz mevcut değil	NA	Yok
Aral K.D. vd. (2012)	AUC	85.7%	Yok
Johnson M.E. vd. (2015)	Doğruluk, Hassaslık (Sensitivity) ve Kesinlik (Specificity)	82% ila 86%	Yok
eFAD Suite (Bu çalışma)	DP	93.5%	4,3% ila 8,7%
	YP	17.6%	
	YN	6.5%	
	DN	82.4%	
	Doğruluk	89.6%	
	AUC	92.2%	

Çalışmamızın sonuçlarının diğer çalışmalarla karşılaştırılması, yukarıda da belirtildiği üzere sadece kullanılan yöntemlerin ve bu yöntemlerle elde edilen sonuçların belirtilmesinden ibarettir. Bu çalışmalar, farklı veri setlerinde ve kapsamda çalıştığı için Tablo 3.1, çalışmaların niteliklerini karşılaştırması değildir.

Bu durumda, çalışmamızın sonuçlarını karşılaştırmamızın sağlıklı yöntemlerinden birisi, bir kalite testi (benchmark) ile sonuçları karşılaştırmaktır. Bu çerçevede bir ZeroR Sınıflayıcı ile çalışma yapılmış ve çalışmamızın sonuçları karşılaştırılmıştır. Tablo 5.6, ZeroR sınıflayıcısının tüm seriler için doğruluk değerlerini göstermektedir. ZeroR sınıflayıcısı ile bizim çalışmamızda elde edilen doğruluk değerlerinin karşılaştırması ise Tablo 5.7’de sunulmaktadır.

Tablo 5.6: ZeroR sınıflayıcısının doğruluk değerleri.

Anormal Davranış	Gerçek	Tahmin		Doğruluk
		Pozitif	Negatif	
A	Pozitif	28	20	58.3%
	Negatif	0	0	
B	Pozitif	31	17	64.5%
	Negatif	0	0	
C	Pozitif	24	24	50%
	Negatif	0	0	
D	Pozitif	22	26	45.8%
	Negatif	0	0	
E	Pozitif	28	20	58.3%
	Negatif	0	0	
F	Pozitif	26	22	54.1%
	Negatif	28	20	

Tablo 5.7: eFAD sistemi ile ve ZeroR sınıflayıcının doğruluk değerleri karşılaştırması.

Anormal Davranış	Gerçek	Tahmin		Doğruluk (eFAD)	Doğruluk (ZeroR)	AUC (eFAD)
		Pozitif	Negatif			
A	Pozitif	89.3%	10.7%	79.2%	58.3%	82.1%
	Negatif	35.0%	65.0%			
B	Pozitif	93.5%	6.5%	89,6%	64.5%	92.2%
	Negatif	17.6%	82.4%			
C	Pozitif	91.7%	8.3%	75.00%	50%	83.3%
	Negatif	41.7%	58.3%			
D	Pozitif	90.9%	9.1%	70.80%	45.8%	75.2%
	Negatif	46.2%	53.8%			
E	Pozitif	89.3%	10.7%	79.20%	58.3%	87.1%
	Negatif	35.0%	65.0%			
F	Pozitif	88.5%	11.5%	75.00%	54.1%	86.4%
	Negatif	40.9%	59.1%			

6. YORUMLAR VE ÖNERİLER

Bu arařtırmada, sađlık sigorta sektöründe sahtecilik ve suistimal vakalarının tespiti için makine öğrenmesi temelli, özgün ve interaktif bir model geliştirilmiştir. Söz konusu model, provizyon aksiyonunda yer alan aktörler ve metâlardan bađımsız, yeni anormal davranıřlar için özelleřtirilebilen ve provizyonların fragmente dođasının dezavantajından etkilenmeyen bir yapıdadır. Ayrıca bu model, reaktif olarak analiz yapabildiđi gibi, çevirim içi olarak analiz yapma imkânı da olan reaktif bir sistemdir. Model, kendi içerisindeki görselleřtirme aracı sayesinde kendisi tarafından riskli olarak tespit edilen provizyonların, uzmanlar tarafından provizyondaki aktör ve iliřkili diđer provizyonlarla birlikte hızlı ve efektif bir şekilde incelenmesini ve nihai kararın en az maliyetle verilebilmesini sađlamaktadır.

Geliřtirilen uygulama, alanında bařarılı uygulaması olan az sayıda çalıřmalardan biridir. Hatırlanacađı üzere, literatürdeki çalıřmaların kısıtlı bir kapsamda inceleme yapmıř olmaları onların gerçek hayatta kullanılmalarını da kısıtlamıřtır. Buna karřın, geliřtirilen model, olası tüm aktörleri ve metaları kapsadıđından ve bunlar arasındaki iliřkileri temsil etmek üzere oldukça geniř bir öznitelik kümesi (138 tane) barındırdıđı için, alanındaki en geniř ve gerçek uygulaması olan modellerden biridir.

Geliřtirilen modelin deneysel çalıřmalar sırasında performansının oldukça tatmin edici olduđu gözlemlenmiř ve hem dođruluđu (accuracy); hem de AUC deđerleri yeterli görüldüđünden, Türkiye’de özel sađlık sigorta sektöründe biliřim çözümleri üreten CGM (CompuGroup Medical) řirketi modeli eFAD Suite ticari adı ile ürün haline getirmiřtir.

CGM, halen bu ürünü kullanarak farklı müřterilerine talepleri dođrultusunda aylık raporlar üreterek daha önceki hasarları içerisinde tespit edilen anormal durumları rapor etmiř ve rapor başına hizmet bedeli almıřtır.

Bununla birlikte, her ne kadar bu model sađlık sigorta sektörü için geliřtirilmiř olsa da, aktör-metâ iliřkisinin analiz edilebileceđi tüm sigortacılık alanlarında uyarlanarak kullanıma uygundur. Bu tür çalıřmalar daha ileri arařtırmalara bırakılmıřtır. Benzer şekilde, bu modelde kullanılan IML yaklařımında uzmanların, öznitelik seçim eđilimleri, sistemin çıktılarını deđerlendirerek daha önceki görüşlerini nasıl ve ne miktarda deđiřtirdikleri, daha sonra yapılacak katma deđerli

çalışmalar için bir araştırma alanı olacaktır. Ayrıca, şuna da dikkate çekmek gerekir ki, bu modelde kullanılan öznitelikler, birer gösterge olarak birbirinden tamamen bağımsız değillerdir. Anlamsal olarak kesişen bazı başka göstergelere sahip oldukları için, bir özneliğin yer aldığı bir anormal davranış tipi ile analiz yapılırken, uzmanların daha önce fark etmedikleri ve bu seri ile yakalamayı beklemedikleri başka bir anormal davranışa dair işaretler bulmaları da olasıdır. Dolayısıyla bağıl ilişkileri olan özniteliklerle bu tür analizler yapmanın etkileri konusunda da bir araştırma yapılabilir.

Diğer taraftan bu çalışmada, öğreticili öğrenme yöntemlerinin provizyon verileri üzerinde uygulanmasının zorluğundan bahsedilmiş ve bu nedenle türetilmiş göstergeler kullanılarak risk hesaplaması temelli bir yaklaşım takip edilmiştir. Bununla birlikte bu türetilmiş göstergelerle etiketleme yapılması ve öğreticili öğrenme yöntemlerinin kullanılmasının denenmesi, hala anlamlı bir araştırma alanı olarak görünmektedir.

Son olarak, bu çalışmada aktör ve metâlar arasındaki ilişkiye odaklanılmış; ancak oldukça değerli olduğunu düşündüğümüz aktör-aktör arasındaki ilişki incelenmemiştir. Bir aktörün riskli olması durumunda, onunla ilişkisi olan diğer aktörlerinde belirli oranda riskli olabileceği tezi ile sahtecilik vakalarının araştırılmasının da son derece önemli olacağını değerlendirmekteyiz.

KAYNAKLAR

- [1] Porter R., Theiler J., Hush D., (2013), "Interactive machine learning in data exploitation", Technical Report No: LA-UR-13-20441, Intelligence and Space Research Division, Los Alamos National Laboratory, USA.
- [2] Fails J. A., Olsen Jr. D. R., (2003), "Interactive machine learning", The 8th International Conference on Intelligent User Interfaces, 39-45, New York, USA, 12-15 January.
- [3] Holzinger A., Jurisica I., (2014), "Knowledge discovery and data mining in biomedical informatics: The future is in integrative, interactive machine learning solutions". In: Holzinger A., Jurisica I., "Interactive Knowledge Discovery and Data Mining in Biomedical Informatics", LNCS 8401, Springer.
- [4] Ware M., Frank E. , Holmes G., Hall M., Witten I. H., (2001), "Interactive machine learning: letting users build classifiers", International Journal of Human-Computer Studies, 55, 281-292.
- [5] Stumpf S., Rajaram V., Li L., Wong W. K., Burnett M., Dietterich T., Sullivan E., Herlocker J., (2009), "Interacting meaningfully with machine learning systems: Three experiments", International Journal of Human-Computer Studies, 67, 639-662.
- [6] Turkay C., Jeanquartier F., Holzinger A., Hauser H., (2014), "On computationally-enhanced visual analysis of heterogeneous data and its application in biomedical informatics". In: Holzinger A., Jurisica I., "Interactive Knowledge Discovery and Data Mining in Biomedical Informatics", LNCS 8401, Springer.
- [7] Holzinger A., (2013), "Human-Computer Interaction and Knowledge Discovery (HCI-KDD): What Is the Benefit of Bringing Those Two Fields to Work Together?". In: Cuzzocrea A., Kittl C., Simos D. E., Weippl E. Xu L., "Availability, Reliability, and Security in Information Systems and HCI" LNCS 8127, Springer.
- [8] Fiebrink R., Cook P. R., Trueman D., (2011), "Human Model Evaluation in Interactive Supervised Learning", 147-156, CHI, BC, Canada, 7-12 May.
- [9] Chandola V., Banerjee A., Kumar V., (2009), "Anomaly Detection: A Survey", ACM Computing Surveys, 41 (3), 1-58.
- [10] Yang WS, (2003), "A Process Pattern Mining Framework for the Detection of Health Care Fraud and Abuse", Doktora Tezi, National Sun Yat-Sen University.
- [11] Bolton R. J., Hand D. J., (2002), "Statistical Fraud Detection: A Review", Statistical Science, 17, 235-255.

- [12] Web 1, (2010), <http://truecostofhealthcare.net/wp-content/uploads/2015/02/cmstables.pdf>, (Eriřim Tarihi: 01/05/2015).
- [13] Kumar M., Ghani R., Mei Z.S., (2010), "Data Mining to Predict and Prevent Errors in Health Insurance Claims Processing", 65-73, 16th ACM SIGKDD, Washington, DC, USA, 25-28 July.
- [14] Web 2, <http://www.cgm.com/tr>, (Eriřim Tarihi: 01/05/2015).
- [15] Web 3, www.agito.com.tr, (Eriřim Tarihi: 01/05/2015).
- [16] Yang W.S., Hwang S.Y., (2006), "A process mining framework for the detection of healthcare fraud and abuse", Expert Systems with Applications, 31, 56-68.
- [17] Fayyad U., Piatetsky-Shapiro G., Smyth P., (1996), "From Data Mining to Knowledge Discovery in Databases", American Association for Artificial Intelligence, Fall, 37-54.
- [18] Web 4, <http://www.nhcaa.org>, (Eriřim Tarihi: 01/05/2015).
- [19] Web 5, https://www.fbi.gov/stats-services/publications/fcs_report2007, (Eriřim Tarihi: 01/05/2015).
- [20] Copeland L., (2011), "Applying Business Intelligence Concepts to Medicaid Claim Fraud Detection", Conference for Information Systems Applied Research, 1-12, Wilmington North Carolina, USA, 3-6 November.
- [21] Derrig R. A., (2002), "Insurance Fraud", The Journal of Risk and Insurance, 69 (3), 271-287.
- [22] Castro D., (2007), "Improving Health Care Why a Dose of it May Be Just What the Doctor Ordered", The Information Technology & Innovation Foundation, October, 1-23.
- [23] Plaisant C., Shneiderman B., (1998), "An Information Architecture to Support the Visualization of Personal Histories, Information Processing and Management", 35, 581-597.
- [24] Web 6, <http://www.nhcaa.org/resources/health-care-anti-fraud-resources/the-challenge-of-health-care-fraud.aspx>, (Eriřim Tarihi: 01/05/2015).
- [25] Phua C., Lee V., Smith K., Gayler R.A., (2005), "Comprehensive Survey of Data Mining", Technical Report: Fraud Detection Research, Monash University, Australia.
- [26] Ngai E. W. T., Yong H., Wong Y. H., Chen Y., Sun X., (2011), "The application of data mining techniques in financial fraud detection: A classification framework and an academic review of literature", Decision Support Systems Journal, 50, 559-569.

- [27] Li J., Huang K. Y., Jin J., Shi J., (2008), "A survey on statistical methods for health care fraud detection", *Health Care Manage Science*, 11, 275-287.
- [28] Joudaki H., Rashidian A., Minaei-Bidgoli B., Mahmoodi M., Geraili B., Nasiri M., Arab M., (2015), "Using Data Mining to Detect Health Care Fraud and Abuse- A Review of Literature", *Global Journal of Health Science*, 7 (1), 194-202.
- [29] He H., Wang J., Graco W., Hawkins S., (1997), "Application of Neural Networks to Detection of Medical Fraud", *Expert Systems with Applications*, 13 (4), 329-336.
- [30] Williams G., (1999), "Evolutionary hot spots data mining: An architecture for exploring for interesting discoveries", 184-193, 3rd Pacific-Asia Conference on Knowledge Discovery and Data Mining, Beijing, Japan, 26-28 April.
- [31] Yamanishi K., Takeuchi J. I., (2004), "On-line Unsupervised Outlier Detection Using Finite Mixture with Discounting Learning Algorithms", *Data Mining and Knowledge Discovery*, 8, 275-300.
- [32] Major J. A., Riedinger D. R., (2002), "EFD: A Hybrid Knowledge/Statistical-Based System for the Detection of Fraud", *Journal of Risk & Insurance*, 69 (3), 309-324.
- [33] Ortega P.A., Figueroa C.J., Ruz G.A., (2006), "A medical claim fraud/abuse detection system based on data mining: A case study in Chile", *The International Conference on Data Mining*, 224-231, Las Vegas, Nevada, USA, 26-29 June.
- [34] Yang W.S., Hwang S.Y., (2006), "A process mining framework for the detection of healthcare fraud and abuse", *Expert Systems with Applications*, 31, 56-68.
- [35] Sokol L., Garcia B., Rodriguez J., West M., Johnson K., (2001), "Using Data Mining to Find Fraud in HCFA Health Care Claims", *Topics in Health Information Management*, 22 (1), 1-13.
- [36] Aral K. D., Guvenir H. A., Sabuncuoglu İ., Akar A. R., (2012), "A prescription fraud detection model", *Computer Methods and Programs in Biomedicine*, 106 (1), 37-46.
- [37] Johnson M.E., Nagarur N., (2015), "Multi-stage methodology to detect health insurance claim fraud", *Healthcare Management Science*, published online 20 January 2015, 1-12.
- [38] Taira H., Fan Y., Yoshiya K., Miyagi H., (1996), "A Method of Constructing Pairwise Comparison Matrix in Decision Making", *Systems, Man, and Cybernetics, IEEE International Conference*, 4, 2511-2516, Beijing China, 14-17 October.

- [39] Dempster A. P., Laird N. M., Rubin D. B., (1977), "Maximum likelihood from incomplete data via the EM algorithm", *Journal of the Royal Statistical Society*, 39 (1), 1-38.
- [40] Chan A. P. C., Yung E. H. K., Lam P.T. I., Tam C. M., Cheung S. O., (2001), "Application of Delphi method in selection of procurement systems for construction projects", *Construction Management and Economics*, 19 (7), 699-718.
- [41] Edwards W., Barron F. H., (1994), "SMARTS and SMARTER: Improved Simple Methods for Multiattribute Utility Measurement", *Organizational Behavior and Human Decision Processes*, 60 (3), 306-325.
- [42] Weber M., Borcherding K., (1993), "Behavioral influences on weight judgments in multiattribute decision making", *European Journal of Operational Research*, 67 (1), 1-12.
- [43] Cabrerizo F.J., Ureña R., Pedrycz W., Herrera-Viedma E., (2014), "Building consensus in group decision making with an allocation of information granularity", *Fuzzy Sets and Systems*, 255, 115–127.
- [44] Herrera F., Herrera-Viedma E., Verdegay J.L., (1997), "A rational consensus model in group decision making using linguistic assessments", *Fuzzy Sets and Systems*, 88, 31-49.
- [45] Wu Z., Xu J., (2012), "A consistency and consensus based decision support model for group decision making with multiplicative preference relations", *Decision Support Systems*, 52, 757-767.
- [46] Herrera-Viedma E., Cabrerizo F. J., Kacprzyk J., Pedrycz W., (2014), "A review of soft consensus models in a fuzzy environment", *Information Fusion*, 17, 4-13.
- [47] Krueger R. A., Casey M. A., (2000), "Focus Groups: A Practical Guide for Applied Research", 3rd Edition, Sage Publications.
- [48] Phua C., Alahakoon D., Lee V., (2004), "Minority Report in Fraud Detection: Classification of Skewed Data", *SIGKDD Explorations*, 6 (1), 50-59.
- [49] Mollahaliloglu S., Alkan A., Donertas B., Ozgulcu S., Akici A., (2011), "Assessment of the Prescriptions Written in Different Provinces of Turkey in Terms of Drug Utilization Principles", *Marmara Medical Journal*, 24, 162-173.

ÖZGEÇMİŞ

Lisans eğitimini 1999 yılında İstanbul Üniversitesi Elektronik Mühendisliği'nde (İng.) tamamlayan İlker KÖSE, 2003 yılında Gebze Yüksek Teknoloji Enstitüsü, Mühendislik ve Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalında yüksek lisansını tamamladı. 2007 yılında Gebze Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalından doktora eğitimine başladı. Bunun yanında, 1999-2003 yıllarında İstanbul Ulaşım AŞ'de Bilgi İşlem Şefi olarak iş hayatına başlayan Sn. KÖSE, 2003-2009 yıllarında Sağlık Bakanlığı'nda Dünya Bankası Bilişim Danışmanı ve Proje Yöneticisi, 2009-2014 yıllarında ise CompuGroup Medical Şirketinde Ar-Ge Direktörü olarak çalışmıştır. 2009 yılından itibaren İstanbul Medipol Üniversitesinde öğretim görevlisi olarak dersler vermeye de başlayan KÖSE, 2014 yılı Kasım ayı itibariyle aynı üniversitede Teknoloji Transfer Ofisi Direktörü olarak görev yapmaktadır.

EKLER

Ek A: Tez Çalışması Kapsamında Yapılan Yayınlar

Kose I., Gokturk M., Kilic K., (2015), “An Interactive Machine-Learning-Based Electronic Fraud and Abuse Detection System In Healthcare Insurance”, Applied Soft Computing, Volume 36, 283-299.

Kose I., Gokturk M., Kilic K., (2010), “Sağlık Geri Ödeme Sistemlerinde Kural Dışı Davranış Tespitinde Aktör-Metâ Odaklı Yaklaşım”, VII. Ulusal Tıp Bilişimi Kongresi, Lefoşe, KKTC, 15-16 Ekim.

Kose I., Gokturk M., Kilic K., (2010), “Sağlık Sigortası Geri Ödemelerinde Kuraldışı Davranış Tespiti”, YAEM 30. Ulusal Kongresi, İstanbul, 30 Haziran-2 Temmuz.