

Bu makaleye atıfta bulunmak için/To cite this article:

ALAN, M.A, YEŞİLYURT, C. (2019). Birliktelik Kuralları Madenciliği İle Yatan Hasta Profiline Çıkarılması. Atatürk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 23 (Özel Sayı) , 1917-1926.

Birliktelik Kuralları Madenciliği İle Yatan Hasta Profiline Çıkarılması

Mehmet Ali ALAN (*)

Cavit YEŞİLYURT (**)

Öz: Bu çalışmada, hastane veri tabanındaki veriler kullanılarak, veri madenciliği yöntemi ile hasta profili çıkarılmaya çalışılmıştır. Bu amaçla 28.738 yatan hastaya ait veriler kullanılarak Birliktelik Kuralları Madenciliği yapılmıştır. Yapılan çalışma sonucunda %60 ve üzeri güven seviyesinde 64 kural üretilebilmiştir. Üretilen bu kuralların hem doktorlara, hem de hastane yöneticilerine karar desteği sağlayacağı düşünülmektedir.

Anahtar Kelimeler: Veri Madenciliği, Birliktelik Kuralları, Hasta Profili

Preparation of Inpatient Profile Via Association Rules Mining

Abstract: In this study, the patient profile was tried to be extracted using data mining method by using the data in the hospital database. For this purpose, 28.738 inpatient data were obtained and the Association Rules Mining was performed. As a result of the study, 64 rules can be produced with a confidence level of 60% and above. It is thought that these rules will provide decision support to both doctors and hospital managers.

Keywords: Data Mining, Association Rules, Inpatient Profile

Makale Geliş Tarihi: 19.07.2019

Makale Kabul Tarihi: 23.11.2019


I.Giriş

Veri madenciliği, pek çok alanda uygulanmaktadır. Bu uygulama alanlarından biri de sağlıktır. Veri madenciliği yöntemlerinin etkili bir şekilde uygulanması hasta, doktor ve hastane işletmecileri açısından yararlı sonuçlar üreteceği açıktır.

Sağlıkta veri madenciliğinin kullanılması, hasta verilerinin içeriğini kaydetmeyi ve yorumlamayı, hem hastaya hem de doktora karar desteği sağlamayı amaçlayan bir izleme ve yönetim sistemidir. Ayrıca, geçmiş ve yakın zamanda kaydedilen tüm verilerle, davranış kalıplarını çıkarmak, yeni bilgiler keşfetmek ve hekimlere destek sağlamak amaçlanmaktadır.

Bilgi keşfetme ve makine öğrenme yöntemleri hem hasta verilerindeki yeni kalıpları keşfetmek için hem de sonuç veya risk değerlendirmesi gibi sınıflandırma ve tahmine yönelik amaçlarla kullanılabilir. Hasta verilerini, hekime bakım noktasında yardım sağlamak için klinik kılavuzlarla bütünleştiren karar destek sistemlerini genişletme potansiyeli vardır.

*) Doç.Dr. Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Fakültesi Yönetim Bilişim Sistemleri Bölümü (e-posta: alan@cumhuriyet.edu.tr)  ORCID ID. orcid.org/0000-0001-8562-547x

**) Doç. Dr. Atatürk Üniversitesi İktisadi ve İdari Bilimler Fakültesi Ekonometri Bölümü (e-posta: cavitiesilyurt@atauni.edu.tr)  ORCID ID. orcid.org/0000-0001-9814-4085

Kişiselleştirilmiş bilgi aktarımı ve hastanın tedavi planlarına rehberlik etmesinin temel şartı, kullanıcının uygun ve doğru bir profilinin geliştirebilmesidir. Bilgisayar destekli bilgi alımı, kaliteli karar vermeyi desteklemeye ve insan hatasından kaçınmaya yardımcı olabilir. Kodlanmış hasta geçmişi ve ilaç bilgileri gibi yapılandırılmış veriler, işlenmesi en kolay veri kaynaklarıdır. Veri madenciliği yöntemlerinde kaydedilen ilerlemeler, hasta profillerinin çıkarılmasını da mümkün kılmıştır. Kaynakları optimize etme yolunda atılan ilk adımlardan biri kapasiteyi verimli kullanmaktır. Hastaların kabulü, yatakların tahsisi gibi hastane kapasite sorunları için, yönetilebilir hasta tipleri gruplarının oluşturulması önemlidir.

Bu çalışmada, bir kamu hastanesine ait veriler kullanılarak, hasta profilleri arasında birliktelik kurallarının olup olmadığı araştırılmaya çalışılmış, böylelikle doktorlara ve hastane yöneticilerine karar süreçlerinde destek sağlanmasına çalışılmıştır.

Çalışma dört bölümden oluşmaktadır. Birinci bölümde veri madenciliği, Birliktelik Kuralları tekniği ve Apriori algoritması ele alınmış, ikinci bölümde literatür özeti sunulmuş, üçüncü bölümde veri seti ve yöntem konusunda bilgi verilmiş, dördüncü bölümde ise yatan hastalara ait verilere yönelik olarak yapılan uygulamaya yer verilmiştir.

II. Veri Madenciliği, Birliktelik Kuralları ve Apriori Algoritması

Veri madenciliği, veri tabanı sistemleri, istatistik, makine öğrenmesi, görselleştirme ve bilişim bilimini kapsayan, disiplinler arası bir alan ve disiplinler kümesinin bileşimidir (Han ve Kamber, 2006: 29). Veri madenciliği, veri tabanlarındaki bilgileri keşfederek çalışılan alana yönelik karar destek sistemleri için gerekli ön bilgileri temin etmede kullanılmaktadır (Fayyad vd., 1996: 38). Farklı bakış açılarından veri analiz etmeye dayalı bilgileri keşfetmenin mümkün olduğu veri madenciliği, reklam, bioinformatik, veri tabanı pazarlaması, sahteciliğin tespiti, e-ticaret, sağlık, güvenlik, web, finansal tahmin vb. konu başlıkları da dâhil olmak üzere çok çeşitli alanlarda uygulama şansı bulabilmektedir (Jain vd., 2011: 2793). Bunlara ilaveten veri madenciliği, önceden bilinmeyen örüntüleri keşfetmek için veri keşfetme bilimi ve teknolojisi olarak, veri tabanlarında bilgi keşfetmeye yönelik genel sürecin bir parçasıdır. Bilgisayar odaklı günümüz dünyasında, veri tabanlarındaki büyük çaptaki bilgiler, keşfedilecek örüntüleri de içerirler. Bu bilgilerin erişilebilirliği ve bolluğu, veri madenciliğini çok önemli ve gerekli hale getirmektedir (Rokach ve Maimon, 2008:1).

Veri madenciliğinde, Birliktelik Kuralları, Kümeleme, Karar Ağaçları, Diskriminant Analizi, Yapay Sinir Ağları, Genetik Algoritmalar vb. gibi çok sayıda teknik bulunmaktadır. Bu teknikler, bir yöneticinin kararlarını yönlendirebilecek bilgileri keşfetme ve bilgi sağlama amacıyla çeşitli alanlardan alınan bilgileri işleme amacıyla kullanılırlar (Wu ve Li, 2003).

Birliktelik Kuralları tekniği, bilgisayar bilimleri alanında geliştirilmiş, ancak daha çok market sepet analizi (belirli bir müşterinin aldığı ürünler arasındaki ilişkiyi ölçen) ve web tıklama analizi (bir web sitesi için ziyaretçi tarafından sıklıkla tıklanan sayfalar arasındaki ilişkileri ortaya koyan) gibi alanlarda uygulanmıştır. Genel olarak amaç, bir

grup işleminde çoğunlukla birlikte meydana gelen parça gruplarının altını çizmektir (Giudici ve Figini, 2009: 90–91). Diğer bir ifade ile Birliktelik Kuralları, büyük veri kümelerindeki değişkenlerin özel değerleri arasında, ilişkinin ve birlikteliklerin tespit edilmesidir. Bu teknik, analizcilerin ve araştırmacıların büyük veri setlerindeki gizli örüntüleri açığa çıkarmalarını sağlar (Nisbet vd., 2009:126). Kullanışlılığı, kolay anlaşılması ve mümkün olan bütün örüntüleri ortaya çıkarması tekniğin güçlü yönüdür. Ancak mümkün olan bütün olasılıkları ortaya çıkarması aynı zamanda onun, bir zayıflığıdır. Çünkü karar vericiler, bütün bu olasılıklarını değerlendirecekleri büyük miktarda bilginin üstesinden gelmek durumunda kalırlar ki bu zor ve zaman alıcı bir durumdur (Kantardzic, 2003: 169).

Market Sepet Analizi olarak da adlandırılan Birliktelik Kuralları tekniği ile daha çok müşterilerin tüketim alışkanlıklarının analizine yönelik değerlendirmeler yapılmaktadır ve satın alma işlemlerinde birlikte oluşma eğilimi olan ürünlerin veya ürün gruplarının tanımlanmasına olanak sağlar (Giudici ve Figini, 2009: 175).

Birliktelik Kuralları tekniğinde, Apriori, Fp-Growth, Tertius gibi algoritmalar kullanılmaktadır. Bu çalışmada Apriori algoritması kullanılmıştır.

Bu algoritma, doğrulama değerlerine göre kural bulur ve birinci dereceden mantıksal gösterimleri kullanır. Bu değerler, sınıf endeksi, sınıf doğrulama eşik değeri, doğrulama değeri, frekans eşik değeri, kayıp değerler ve veriler, gürültü eşik değeri, sayı kalıpları, tekrar kalıpları, ROC analizi ve çıktı değerleri gibi değişik seçenekleri içerir (Arora vd., 2013). Apriori, doğrulama değerlendirme fonksiyonunun en yüksek değerlerine sahip sonuçlarını arayan, bir tümevarımsal mantık programlama algoritmasıdır. Göreceli doğrulukla ağırlıklandırılmış en basit farklı doğrulama ölçülerini araştırır. Bir doğrulama ölçütü, bir kuralın umulmadık ve beklenen karşı örneklerin kısmını gösterir. Algoritmada beklenen ve gözlenen olasılığa sahip iki değer hesaplanır. Apriori, birinci dereceden kuralları ayıklar ve diğer programlarla birliktelik kuralları madencilik görevlerinde kullanılır (Nahar vd., 2013).

Apriori algoritması, birliktelik kuralları madenciliğinde standart bir yaklaşım haline gelmiştir. İlk önce Agrawal ve Srikant (1994) tarafından tanıtılmıştır. Algoritma, işlemleri içeren bir veri kümesiyle başlar ve en azından bir kullanıcı tarafından belirlenen eşığe sahip olan sık ürün setleri oluşturmayı amaçlar. Apriori'nin algoritmik işleminde, k uzunluğundaki X kümesinin bir ögesi, k uzunluğuna sahip olan her X alt kümesinin de sık olması durumunda sık görülür. Bu değerlendirme, arama alanının önemli ölçüde azaltılmasına neden olur ve hesaplamalı olarak uygun bir zamanda kural keşfi sağlar. Güven, temel olarak kuralın doğruluğudur ve Apriori'de kuralları sıralamak için kullanılır (Nahar et al., 2013: 1086–1093)

Apriori Algoritmasının genel yapısı aşağıdaki gibidir:

Apriori Algoritması

```
F1 = {1 elemanlı sık görülen ürün kümeleri};  
For (k= 1; Fk ≠ ∅; k++) do begin  
    Ck+1 = apriori-gen (Fk); // Yeni adaylar  
    for all işlemler t ∈ Database do begin  
        C't = altküme(Ck+1, t); // t içindeki adaylar  
        For all adaylar c ∈ C't do  
            c.count++;  
        End  
    Fk+1 = {c ∈ Ck+1 | c.count ≥ minimum support}  
    End  
End  
Answer UkFk;
```

Birliktelik kurallarında başlangıçta kullanılan iki istatistik destek (*support*) değeri ve güven (*confidence*) seviyesidir. Bunlar sayısal değerlerdir ve bunları tanımlamak için bazı sayısal terimlerin tanımlanması gerekir. D işlemlerin veritabanı, N de D deki işlemlerin sayısı olsun. Her D_i işlemi bir ürün kümesidir. $Destek(X)$ de X ürün kümesini içeren işlemlerin oranı olsun:

$$Destek(X) = \frac{|\{I \mid I \in D \wedge I \supseteq X\}|}{N}$$

I bir eleman kümesi ve $|\cdot|$ de kümenin eleman sayısını göstermektedir.

Bir birliktelik kuralının destek değeri, önceki ve sonraki nin her ikisinin de bulunduğu işlemlerin toplam işlem sayısına oranıdır. Güven değeri ise, öncekini içeren işlemlerin aynı zamanda sonrakini de bulundurma oranıdır. $A \Rightarrow C$ birlikteliği için destek ve güven değerleri aşağıdaki gibidir (Webb, 2003):

$$Destek(A \Rightarrow C) = Destek(A \cup C)$$

$$Güven(A \Rightarrow C) = Destek(A \cup C) / Destek(A)$$

Eğer destek değeri yeterince yüksekse (ve işlemler, gelecekteki işlemler ile aynı veri dağıtımından rasgele bir örneği temsil ediyorsa), o zaman güven seviyesi, kuralın birinci tarafını içeren herhangi bir gelecekteki işlemin, aynı zamanda, kuralın ikinci tarafını da içereceği ihtimalinin makul bir tahminidir (Webb, 2003:27-28).

Birliktelik kurallarında kullanılan destek ve güvenden başka bir değer hesaplama ise “lift” değeridir. Lift değeri şu şekilde hesaplanır:

$$Lift(A \Rightarrow C) = \frac{güven(A \Rightarrow C)}{destek(C)}$$

İşlem sonucunun 1’den küçük olması A’nın görülmesinin C’nin görülmesi üzerinde negatif korelasyona sahip olduğunu; 1’den büyük olması A’nın görülmesinin C’nin görülmesi üzerinde pozitif korelasyona sahip olduğunu ifade eder ki bunun anlamı, birinin görülmesi ile diğ erinin görülmesi ilişkilidir. Eğer lift değeri 1 çıkmış ise bu iki tarafın birbirinden bağımsız olduğu anlamına gelir (Taş, 2018:37-38).

III. Literatür Özeti

Konuyla ilgili literatürde benzer veri setleri üzerinden yapılmış çok sayıda çalışma bulunmaktadır. Bunlardan;

Erdem, Özdağođlu (2008), Ege Bölgesindeki bir araştırma ve uygulama hastanesinin acil servisine başvuruda bulunan hasta verileri ile birliktelik kuralı yöntemiyle ilişkiler ortaya çıkarmış ve belirli bir destek ve güven değerine göre yapılan analizler sonucunda 65 anlamlı kurala ulaşmışlardır. Elde edilen kurallardan yaş ve cinsiyet gruplarına göre acil servise başvuru zamanları ve kalış sürelerine ilişkin verileri dikkate alarak hasta profilini çıkarmışlardır. Bu bilgilerin, acil servis açısından kapasite ve eylem planlarında karar vericilere destek olabileceğine vurgu yapmışlardır.

Krishnaiah vd. (2013), klinik tahminlerin idari, klinik, araştırma ve eğitimsel yönlerinde veri madenciliği tekniklerini uygulamışlardır. Bu makale, sağlıkla ilgili problemlerde veri madenciliğinin, klinik araştırmaların çeşitli yönlerini iyileştirmek için veri madenciliği teknikleri için büyük bir potansiyel bulunduğunu ortaya koymuşlardır. Ayrıca, veri madenciliği tekniklerinin kaliteyi iyileştirme ve sağlık hizmetlerinin maliyetini düşürme potansiyeline vurgu yapmışlar, ayrıca, Klinik Tahminlerin çeşitli yönlerini iyileştirebilecek tıbbi veri madenciliği tekniklerini tartışmışlardır.

Tsumoto vd.(2011), bir hastane bilgi sisteminde depolanan verilere, veri madenciliği uygulamasını sunmuşlardır. Sonuç göstermiştir ki depolanan verilerin tekrar kullanılması hastane hizmetlerinin kalitesini artırmak için güçlü bir araç sunmakta ve hastane hizmetlerinin iyileştirilmesine yol açmaktadır.

Mark W. Isken and Balaji Rajagopalan (2012), hastanelerde hasta akışının analitik modellerini oluşturmak amacıyla hasta tipi tanımlarının geliştirilmesine rehberlik etmek için veri madenciliği tekniklerinden, K-means gibi kümeleme teknikleri kullanma potansiyelini göstermişlerdir.

Nahar vd (2013), üç farklı birliktelik kuralı madenciliği algoritması (Apriori, Predictive Apriori ve Tertius) kullanılarak kalp hastalığı verileri üzerinde bir kural çıkarımı sunmuşlardır. Cinsiyete dayalı verileri sınıflandırarak, kural madenciliği

temelli analiz yapmışlar ve hem erkek hem de kadınlar için kalp hastalığı için önemli risk faktörleri bulmuşlardır.

Çoban vd. (2015), çalışmalarında veri madenciliği kapsamına giren büyük boyutlu verilerden anlamlı bilgi çıkarılması amacıyla Atatürk Üniversitesi Araştırma Hastanesi Acil Servis bölümü hasta bilgileri kullanılmıştır. Veri setinde bulunan parametreler doğrultusunda servise gelen hasta profilini ortaya koyabilecek anlamlı bilgilerin çıkarımı için bir veri madenciliği yöntemi olan Apriori algoritması kullanılmıştır. Deneysel sonuçlar servise sıklıkla gelen hastaların cinsiyet, yaş grubu, doğum yeri ve konulan tanı bilgileri kullanılarak hasta profilinin çıkarılması konusunda yol gösterici olacağını düşünülen anlamlı verilerin elde edilebileceğini göstermiştir.

IV. Veri Seti ve Yöntem

Çalışmada bir kamu hastanesinden temin edilen yatan hasta verilerinden yararlanılmıştır. Bu veriler kullanılarak birliktelik kuralları madenciliği yapılmıştır. Bu bağlamda 28.738 yatan hastaya ait veriler Excel makroları kullanılarak gerekli dönüşüme tabi tutulmuş ve veri ambarı hazırlanmıştır.

Veri ambarı, yönetim karar desteklerinde kullanılan konu odaklı, zaman varyantlı ve güncellenemez verilerin toplamıdır. Veri ambarı, meta, gerçek, boyutsal ve kümelenmiş bir veridir ve insanların bilgilendirilmiş kararları vermesini sağlayan, uygun bilgileri tedarik eden bir süreç yöneticisidir (Bose vd., 2009:190).

Çalışmada tam eğitimli set kullanılmıştır. Kullanılan değişkenler ve değişkenlerin aldığı değerler Tablo 1'deki gibidir.

Tablo 1. Değişkenleri ve Aldığı Değerler

Değişken Adı/Aldığı Değer	1	2	3
Cinsiyet	Kadın	Erkek	
Yaş	Yaş<40	40<=Yaş<=60	Yaş>60
Yatış Gün	1 Gün	1 Günden Fazla	
Hastaneye Giriş	Öğleden Önce	Öğleden Sonra	
Sonuç	Şifa ile Taburcu	Diğer	

V. Uygulama

Yapılan çalışmada Weka programının 3.7.2 sürümü kullanılmıştır. Weka programı, açık kaynak kodlu bir yazılımdır. Bu program pek çok sınıflandırma, kümeleme ve Birliktelik Kurallarına ait algoritmayı desteklemektedir.

Mevcut verilerin, Weka programınca da desteklenen Apriori algoritmasının uygulanması ile % 60 ve üzeri güven seviyende 64 kural üretilebilmiştir. Tablo 1'de sunulan sonuçlara göre, Apriori algoritmasıyla üretilen kurallarda “==>” işaretinin sol tarafı kuralın birinci koşulunu; sağ tarafı ise ikinci koşulunu göstermektedir. Kuraldaki Conf (Confidence) güven seviyesini vermektedir. Kuralın sonunda ise lift değeri yer almaktadır. Aşağıda %60 ve üzeri güven seviyesi ile üretilen 64 kural verilmiştir.

Tablo 2. Apriori Algoritmasıyla Üretilen Kurallar

1. Yas=3 Sonuc=2 7112 ==> YatisGun=2 5806 <conf:(0.82)> lift:(1.3)
2. Yas=3 Cinsiyet=2 5151 ==> YatisGun=2 4089 <conf:(0.79)> lift:(1.27)
3. Yas=3 GirisZamani=1 Sonuc=2 4398 ==> YatisGun=2 3470 <conf:(0.79)> lift:(1.26)
4. Yas=3 10401 ==> YatisGun=2 8084 <conf:(0.78)> lift:(1.24)
5. Yas=3 Cinsiyet=1 5250 ==> YatisGun=2 3995 <conf:(0.76)> lift:(1.21)
6. Yas=3 GirisZamani=1 6813 ==> YatisGun=2 5111 <conf:(0.75)> lift:(1.2)
7. GirisZamani=2 Sonuc=2 5731 ==> YatisGun=2 4253 <conf:(0.74)> lift:(1.18)
8. Cinsiyet=2 GirisZamani=2 4464 ==> YatisGun=2 3247 <conf:(0.73)> lift:(1.16)
9. Cinsiyet=2 Sonuc=1 6049 ==> GirisZamani=1 4382 <conf:(0.72)> lift:(1.09)
10. Yas=3 YatisGun=2 8084 ==> Sonuc=2 5806 <conf:(0.72)> lift:(1.35)
11. YatisGun=1 Sonuc=1 5915 ==> GirisZamani=1 4192 <conf:(0.71)> lift:(1.07)
12. Sonuc=1 13448 ==> GirisZamani=1 9504 <conf:(0.71)> lift:(1.07)
13. YatisGun=2 Sonuc=1 7533 ==> GirisZamani=1 5312 <conf:(0.71)> lift:(1.06)
14. YatisGun=1 10708 ==> GirisZamani=1 7507 <conf:(0.7)> lift:(1.06)
15. Yas=3 Cinsiyet=1 5250 ==> Sonuc=2 3666 <conf:(0.7)> lift:(1.31)
16. YatisGun=1 Cinsiyet=1 6499 ==> GirisZamani=1 4515 <conf:(0.69)> lift:(1.05)
17. Cinsiyet=1 Sonuc=1 7399 ==> GirisZamani=1 5122 <conf:(0.69)> lift:(1.04)
18. YatisGun=1 Sonuc=2 4793 ==> GirisZamani=1 3315 <conf:(0.69)> lift:(1.04)
19. Cinsiyet=1 Sonuc=2 7969 ==> YatisGun=2 5485 <conf:(0.69)> lift:(1.1)
20. Yas=1 Sonuc=1 5979 ==> GirisZamani=1 4111 <conf:(0.69)> lift:(1.04)
21. Sonuc=2 15290 ==> YatisGun=2 10497 <conf:(0.69)> lift:(1.09)
22. Cinsiyet=2 Sonuc=1 6049 ==> YatisGun=2 4149 <conf:(0.69)> lift:(1.09)
23. Cinsiyet=2 13370 ==> YatisGun=2 9161 <conf:(0.69)> lift:(1.09)
24. Cinsiyet=2 Sonuc=2 7321 ==> YatisGun=2 5012 <conf:(0.68)> lift:(1.09)
25. Yas=3 10401 ==> Sonuc=2 7112 <conf:(0.68)> lift:(1.29) lev:(0.05) [1578]
26. Yas=3 YatisGun=2 GirisZamani=1 5111 ==> Sonuc=2 3470 <conf:(0.68)> lift:(1.28)
27. YatisGun=1 Sonuc=1 5915 ==> Cinsiyet=1 4015 <conf:(0.68)> lift:(1.27)
28. Yas=2 8934 ==> GirisZamani=1 6044 <conf:(0.68)> lift:(1.02)
29. Yas=2 Cinsiyet=1 5523 ==> GirisZamani=1 3724 <conf:(0.67)> lift:(1.02)
30. GirisZamani=2 9675 ==> YatisGun=2 6474 <conf:(0.67)> lift:(1.07)
31. Yas=3 Cinsiyet=2 5151 ==> Sonuc=2 3446 <conf:(0.67)> lift:(1.26)
32. Cinsiyet=2 13370 ==> GirisZamani=1 8906 <conf:(0.67)> lift:(1)
33. Cinsiyet=2 GirisZamani=1 8906 ==> YatisGun=2 5914 <conf:(0.66)> lift:(1.06)
34. Yas=1 Cinsiyet=2 4808 ==> GirisZamani=1 3188 <conf:(0.66)> lift:(1)
35. Yas=1 GirisZamani=1 6206 ==> Sonuc=1 4111 <conf:(0.66)> lift:(1.42)
36. Cinsiyet=1 15368 ==> GirisZamani=1 10157 <conf:(0.66)> lift:(1)
37. Yas=1 9403 ==> GirisZamani=1 6206 <conf:(0.66)> lift:(0.99)
38. Yas=3 Cinsiyet=2 5151 ==> GirisZamani=1 3398 <conf:(0.66)> lift:(0.99)
39. YatisGun=2 GirisZamani=2 6474 ==> Sonuc=2 4253 <conf:(0.66)> lift:(1.23)
40. Yas=1 YatisGun=2 4868 ==> Sonuc=1 3195 <conf:(0.66)> lift:(1.4)
41. Cinsiyet=1 GirisZamani=1 Sonuc=2 5035 ==> YatisGun=2 3299 <conf:(0.66)> lift:(1.04)
42. Yas=3 10401 ==> GirisZamani=1 6813 <conf:(0.66)> lift:(0.99)
43. GirisZamani=1 Sonuc=2 9559 ==> YatisGun=2 6244 <conf:(0.65)> lift:(1.04)
44. Yas=3 Cinsiyet=1 5250 ==> GirisZamani=1 3415 <conf:(0.65)> lift:(0.98)
45. Yas=2 YatisGun=2 5078 ==> GirisZamani=1 3288 <conf:(0.65)> lift:(0.98)
46. YatisGun=2 Cinsiyet=2 9161 ==> GirisZamani=1 5914 <conf:(0.65)> lift:(0.97)
47. Yas=3 GirisZamani=1 6813 ==> Sonuc=2 4398 <conf:(0.65)> lift:(1.21)

48. YatisGun=2 18030 ==> GirisZamani=1 11556 <conf:(0.64)> lift:(0.97)
49. YatisGun=2 Cinsiyet=1 8869 ==> GirisZamani=1 5642 <conf:(0.64)> lift:(0.96)
50. Yas=1 9403 ==> Sonuc=1 5979 <conf:(0.64)> lift:(1.36)
51. Yas=3 YatisGun=2 8084 ==> GirisZamani=1 5111 <conf:(0.63)> lift:(0.95)
52. Cinsiyet=1 Sonuc=2 7969 ==> GirisZamani=1 5035 <conf:(0.63)> lift:(0.95)
53. Sonuc=2 15290 ==> GirisZamani=1 9559 <conf:(0.63)> lift:(0.94)
54. Cinsiyet=1 GirisZamani=2 5211 ==> YatisGun=2 3227 <conf:(0.62)> lift:(0.99)
55. YatisGun=2 Cinsiyet=1 8869 ==> Sonuc=2 5485 <conf:(0.62)> lift:(1.16)
56. Yas=3 Sonuc=2 7112 ==> GirisZamani=1 4398 <conf:(0.62)> lift:(0.93)
57. Yas=2 8934 ==> Cinsiyet=1 5523 <conf:(0.62)> lift:(1.16)
58. Cinsiyet=2 Sonuc=2 7321 ==> GirisZamani=1 4524 <conf:(0.62)> lift:(0.93)
59. YatisGun=1 Cinsiyet=1 6499 ==> Sonuc=1 4015 <conf:(0.62)> lift:(1.32)
60. Yas=2 GirisZamani=1 6044 ==> Cinsiyet=1 3724 <conf:(0.62)> lift:(1.15)
61. YatisGun=1 10708 ==> Cinsiyet=1 6499 <conf:(0.61)> lift:(1.13)
62. GirisZamani=1 19063 ==> YatisGun=2 11556 <conf:(0.61)> lift:(0.97)
63. YatisGun=2 Cinsiyet=1 Sonuc=2 5485 ==> GirisZamani=1 3299 <conf:(0.6)> lift:(0.91)
64. YatisGun=1 GirisZamani=1 7507 ==> Cinsiyet=1 4515 <conf:(0.6)> lift:(1.12)

Yukarıdaki tablodan da anlaşılacağı gibi üretilen ilk kurala göre, 60 yaşından büyük, şifa dışında bir seçenikle ayrılan 7.112 hastadan, 5.806'sının hastanede 1 günden fazla yattığı anlaşılmaktadır. Bu kuralın güven seviyesi 0.82 ve lift değeri 1,3'tür.

İkinci kurala göre yaşı 60'tan büyük, cinsiyeti Erkek olan 5.151 hastadan, 4.089'unun hastanede 1 günden fazla yattığı ortaya çıkmaktadır. Bu kuralın güven seviyesi 0.79 ve lift değeri 1.27'dir.

Üçüncü kurala göre, 60 yaşından büyük, hastaneye öğleden önce gelen ve şifa dışında bir seçenikle hastaneden ayrılan 4.398 hastadan, 3.470'inin hastanede 1 günden fazla kaldığı anlaşılmaktadır. Bu kuralın güven seviyesi 0.79 ve lift değeri 1.26'dır.

Geri kalan 61 kural için de yukarıdaki yorumlara benzer yorumlar yapılabilir.

VI. Sonuç

Hastane hizmetlerinin yerine getirilmesinde en önemli amaçlardan biri hasta memnuniyetinin sağlanması, bunun için de hasta profilinin ortaya konmasıdır.

Bu çalışma ile hastane yöneticilerine karar alma süreçlerinde, hasta profilinin belirlenmesi ile katkı sağlamak amaçlanmıştır. Çalışmanın amacını gerçekleştirebilmek için veri madenciliğinin birliktelik kuralları tekniğinden yararlanılmıştır.

Çalışmada bir kamu hastanesinden elde edilen 28.738 yatan hastaya ait veriler birliktelik kuralları madenciliği ile analiz edilmiştir. Bu amaçla, veriler, Weka Programının 3.7.2 sürümü kullanılarak Apriori algoritması ile analize tabi tutulmuştur.

Analiz sonucunda, %60 ve üzeri güven seviyesinde 64 birliktelik kuralı tespit edilmiştir. Üretilen ilk kurala göre 60 yaşından büyük, şifa dışında bir seçenikle hastaneden ayrılan 7.112 hastadan, 5.806'sının hastanede 1 günden fazla yatan hastalardan olduğu anlaşılmıştır. Bu kurala benzer 63 kural daha tespit edilmiştir.

Bu kurallara göre, hasta profillerinin dikkate alınmasının, hem hastane yönetimine, hem de doktorlara yararlı bilgi sağlayacağı düşünülmektedir. Bu sonucun da hasta memnuniyetine katkı sağlayacağı, bunun da sağlık hizmetlerinin iyileştirilmesinde destek olacağı değerlendirilmektedir.

Kaynaklar

- Agrawal, R., & Srikant, R. (1994). "Fast Algorithms for Mining Association Rules". *In Proceedings of the 20th International Conference on Very Large Data Bases*, Santiago, Chile. Citeseer (487–499).
- Arora, Jyoti; Bhalla, Nidhi and Rao, Sanjeev (2013), 'A Review On Association Rule Mining Algorithms' *International Journal of Innovative Research in Computer and Communication Engineering* 1.5: 1246-1251.
- Bose, I., Chun, L. A., Yue, L. V. W., Ines, L. H. W. and Helen, W. O. L. (2009), 'Business Data Warehouse: The Case of Wal-Mart', *Data Mining Applications for Empowering Knowledge Societies*, Ed. Hakikur Rahman, Information Science Reference, 189-198.
- Çoban, Ö., Karabey, I., Günay, F.B (2015), "Acil Servis Verilerinden Birliktelik Kuralı (Apriori) Yöntemi ile Hasta Profiline Çıkarılması", 2. *Ulusal Yönetim Bilişim Sistemleri Kongresi*, Erzurum, 275-282.
- Erdem, S., Özdağoğlu, G. (2008), "Ege Bölgesi'ndeki Bir Araştırma Ve Uygulama Hastanesinin Acil Hasta Verilerinin Veri Madenciliği İle Analiz Edilmesi", *Anadolu Üniversitesi Bilim Ve Teknoloji Dergisi Anadolu University Journal Of Science And Technology*, 9(2) : 261-270.
- Fayyad, U., G. Piatetsky-Shapiro, and Padhraic S. (1996). 'From Data Mining to Knowledge Discovery in Databases' *AI magazine* 17.3, 37-54.
- Giudici, P. and Figini, S. (2009), *Applied Data Mining For Business and Industry*, Second Edition, Wiley Publication, West Sussex.
- Han, J., and Micheline K. (2006). *Data Mining, Southeast Asia Edition: Concepts and Techniques*. Morgan Kaufmann.
- Isken, M. W. and Rajagopalan, B. (2002). "Data Mining to Support Simulation Modeling of Patient Flow in Hospitals", *Journal of Medical Systems*, 26(2), 179-197.
- Jain, Yogendra K., Vinod Kumar Y., and Geetika S. P. (2011). 'An efficient association rule hiding algorithm for privacy preserving data mining' *International Journal on Computer Science and Engineering* 3(7), 2792-2798.
- Kantardzic, M. (2003). *Data Mining: Concepts, Models, Methods, and Algorithms*, John Wiley & Sons J. B. Speed Scientific School, University of Louisville IEEE Computer Society, Sponser.

- Krishnaiah, V., Narsimha, G. & Chandra, N. S. (2013), 'A Study On Clinical Prediction Using Data Mining Techniques', *International Journal of Computer Science Engineering and Information Technology Research (IJCEITR)* ISSN 2249-6831 3(1), 239-248,
- Maimon, O., and Lior R. (2008), *Data Mining with Decision Trees: Theory and Applications*, World Scientific New Jersey.
- Nahar J, Imam T, Tickle KS, Chen YP (2013) 'Association Rule Mining To Detect Factors Which Contribute To Heart Disease in Males And Females', *Expert Systems with Applications* 40.
- Nisbet, R., J. Elder IV, and G. Miner, (2009). *Handbook of Statistical Analysis and Data Mining Applications*. Elsevier Inc, Burlington.
- Taş, Y. (2018). *Birliktelik Kuralları Madenciliği Ve Bir Uygulama*, (Yayımlanmamış Yüksek Lisans Tezi), Sivas: Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü.
- Tsumoto, S., Hirano, S., Tsumoto, Y. (2011), "Information Reuse in Hospital Information Systems: A Data Mining Approach", *IEEE IRI*, August 3-5, , Las Vegas, Nevada,:172-176
- Webb, G.,I. (2003). Association Rules. In Nong Ye (Edt.), *The Handbook Of data Mining* (27-28). New Jersey: Lawrence Erlbaum Associates, Inc.
- Wu, T. and L. Xiangyang (2003), 'Data Storage and Management', *The Handbook of Data Mining*, Ed. Nong Ye, New Jersey: Lawrence Erlbaum Associates, Inc. 393-407.