XII ULUSLARARASI TIP BİLİŞİMİ KONGRESİ

15-16 Kasım 2019 I Ankara

TIPTA SANAL GERÇEKLİK

Tıp Bilişimi Derneği

Bildiriler Kitabı / *Proceedings*

Editörler / *Editors*
Oğuz Dicle, Adil Alpkoçak, Mustafa Özmen
Utku Şenol, Neşe Zayim, Yeşim Aydın Son, Gökhan Karakülah

XII. Tıp Bilişimi Kongresi

XIIth Congress of Medical Informatics

Tıp Bilişimi Derneği

Bildiriler Kitabı

Proceedings

Editörler / *Editors*
Oğuz Dicle
Adil Alpkoçak
Mustafa Özmen
Utku Şenol
Neşe Zayim
Yeşim Aydın Son
Gökhan Karakülah

Kasım 2019
Ankara

Kongre Başkanı
Oğuz Dicle, *Dokuz Eylül Üniversitesi*

Düzenleme Komitesi
Adil Alpkoçak, *Dokuz Eylül Üniversitesi*
Gökhan Karakülah, *Dokuz Eylül Üniversitesi*
Mustafa Özmen, *Hacettepe Üniversitesi*
Nese Zayim, *Akdeniz Üniversitesi*
Oguz Dicle, *Dokuz Eylül Üniversitesi*
Utku Senol, *Akdeniz Üniversitesi*
Yesim Aydin Son, *ODTÜ*

Bilimsel Kurul / *Program Committe*
Adil Alpkoçak, *Dokuz Eylül Üniversitesi* (Başkan/*Chair*)
Ahmet Yardımcı, *Akdeniz Üniversitesi*
Akif Muhtar Öztürk, *Gazi Üniversitesi*
Kemal Hakan Gülkesen, *Akdeniz Üniversitesi*
Kemal Turhan, *Karadeniz Teknik Üniversitesi*
Mehmet Ali Ergün, *Gazi Üniversitesi*
Mustafa İlhan, *Gazi Üniversitesi*
Mustafa Özmen, *Hacettepe Üniversitesi*
Oğuz Dicle, *Dokuz Eylül Üniversitesi*
Osman Saka, *Yakın Doğu University*
Selen Bozkurt, *Akdeniz Üniversitesi*
Uğur Bilge, *Akdeniz Üniversitesi*
Utku Şenol, *Akdeniz Üniversitesi*
Yesim Aydın Son, *Ortadoğu Teknik Üniversitesi*
Yilmaz Kemal Yüce, *Alanya Alaattin Keykubat Üniversitesi*
Zerrin Işık, *Dokuz Eylül Üniversitesi*

Web ve Sosyal Medya
Alırıza Arıbaş, *Dokuz Eylül Üniversitesi*

Serbest Bildiriler – I *Prof. Dr. Osman Saka*	
Gizem Kayar, Arda Tümay, Hayri Durmaz and Tuncay Veysel Peker	Oyunlaştırma Tabanlı ve WEB Destekli Anatomi Platformu Geliştirilmesi
Müşerref Duygu Saçar Demirci	Challenges of Big Data in Machine Learning Based MicroRNA Analysis
Mert DemİrarsIan, Yüksel Özkan and Aslı Suner	Kolorektal Kanser Histolojik Doku Görüntülerinde Veri Ön İşleme Sonrasında Öznitelik Çıkarımının Sınıflandırma Performansına Etkisi
Yüksel Özkan, Mert Demirarslan and Aslı Suner	Sağlık Verilerinde Veri Ön İşleme Sonrası Topluluk Öğrenme Sınıflandırma Algoritmalarının Performans Değerlendirmesi
Arda Hadimioglu and Utku Senol	MRG ve BT tetkik sayılarının sağlık göstergeleri ile ilişkisi: Kümeleme ve Korelasyon Analizi
Neslihan Baki, Erman Esnafoğlu, Kemal Turhan and Cansu Gündoğan	Erken Çocukluk Döneminde Otizm Spektrum Bozukluğu Teşhisine Yönelik Bir Tahmin Model Önerisi
Naciye Sinem Gezer, Mustafa Mahmut Barış, Ali Emre Kavur, Ulaş Yüksel, Oğuz Dicle and Mustafa Alper Selver	Comparatıve Analysis of Manual Delineation, Semi-Automatic Extraction and Automatıc Deep Models For Segmentation In Liver Volumetry From MRI
Burcu Sengez, Nazmiye Arslan, Gokhan Karakulah and Hani Alotaibi	Mezenkimal epitelyal dönüşüm (MET) sürecini düzenleyen transkripsiyon faktörlerinin epigenetik yeniden programlama süreci üzerindeki etkilerinin saptanması
Serbest Bildiriler – II *Prof. Dr. Kemal Turhan*	
Filiz İşleyen, Berrak Bora Başara and M. Mahir Ülgü	Uluslararası Hastalık Sınıflandırmasında Yeni Revizyon: ICD-11
Ozan Konur, Alper Selver and Levent Cavas	Sualtı Ragbisi İçin Oyuncu Takip ve Analizi
Hasibe Yıldız and Neşe Zayim	Mobil Sağlık Uygulamalarında Kullanılabilirlik: Göz İzleme Teknolojileri
Gözde Ünal, Filiz İşleyen and Esra Muş	Yoğun Bakım Bilgi Yönetim Sistemlerinin Sağlaması Gereken Temel Özellikler
Göksu Bozdereli Berikol and Nese Zayim	Klinik Araştırmalarda Bilgi Sistemleri: Nitel Bir İhtiyaç Analizi
Mohammad Barakat and Adil Alpkocak	PubMed Article Recommendation System Based on Collaborative Filtering
Nizar Ahmed and Adil Alpkocak	Overview of Word Embedding in Medical Domain
Fatih Dilmaç and Adil Alpkoçak	Automatic assignment of MESH Keywords to PUBMED articles
Göksu Bozdereli Berikol, Ugur Bilge and Gürkan Berikol	Cardiopulmonary Resuscitation Training with Virtual Reality

Oyunlaştırma Tabanlı ve WEB Destekli Anatomi Platformu Geliştirilmesi

Gizem Kayar[1], Arda Tümay[2], Hayri Durmaz [3], Tuncay V. Peker [4]

[1] Yaşar Üniversitesi Bilgisayar Mühendisliği Bölümü, İzmir, Türkiye
gizem.kayar@yasar.edu.tr
[2] Milsoft, Ankara, Türkiye
arda.tumay@tedu.edu.tr
[3] Aselsan, Ankara, Türkiye
hayri.durmaz@tedu.edu.tr
[4] Gazi Üniversitesi Tıp Fakültesi, Ankara, Türkiye
tpeker@gazi.edu.tr

Gamification-Based WEB Supported Anatomy Platform Development

Abstract. Gameplay instinct in human nature plays important role in learning and gaining experience processes since our young ages. A game is the combination of system, players, real-life-imitating core structure, rules, challenge, interaction, feedback and measurable results. Gamification can be described as the usage of game-based mechanics and thinking to motivate people, encourage them for learning and make them solve problems. Many case studies show that gamification increases the pace or improves the quality of learning in various disciplines. Medicine field has a great potential for this, too. In the past, physicians are preferred to be trained only with classical book information, while in today's world, all kinds of technological knowledge and innovation can be used actively by physicans with a clasical background. A physican can diagnose and treat well only by internalizing the human body appropriately. Medical students have difficulty in understanding the connection in between many organs and their surrounding anatomical structures. Anatomy atlases offer only two dimensional (2D) static images. Their effectiveness is limited when compared to the three dimensional (3D) dynamic images. Today, in parallel with developments in computer hardware/software, the usage of digital material is preferred as an alternative to the classical teachings of cadavers. But these are still insufficient. Here it is vital to develop and use these technologies in line with the needs of our time. Our platform aims medical students comprehensively understand a realistic description of the human anatomy atlas, and maximize learning by Virtual Reality integration and especially by using game elements. In addition, with the web UI we developed, the instructors can easily feed our platform online and create virtual exams.

Keywords: Gamification, 2D-3D Medical Modeling, Medical Animation Virtual Reality, Anatomical Games.

[2,3]: These authors contributed equally to this work.

Özet. Genç yaşlarımızdan itibaren insan doğasındaki oyun içgüdüsü öğrenme ve deneyimleme süreçlerimizde önemli bir rol oynar. Oyun, sistem, oyuncu, gerçek-hayat imitasyonu çekirdek yapı, kurallar, zorluklar, etkileşim, geribildirim ve ölçülebilir sonuçların bir bütünüdür. Oyunlaştırma da, oyun-tabanlı mekaniklerin, insanları düşünmeye motive etme, öğrenme için heveslendirme ve problem çözmeye yaklaştırma için kullanılmasıdır. Pek çok çalışma gösteriyor ki oyunlaştırma farklı disiplinlerde öğrenme hızını artırdığı gibi öğrenme kalitesini de artırmaktadır. Tıp da bu alanlardan biri olma niteliğindedir. Önceleri, tıp doktorları klasik eğitim kitapları ile eğitim görüyorlardı. Ancak günümüzde klasik eğitim altyapısı ile gelen doktorlar dahi teknolojik bilgiyi ve yenilikleri aktif olarak kullanmaktadır. Bir tıp doktorunun yerinde teşhis koyması ancak insan anatomisini çok iyi anlaması ile mümkündür. Ancak tıp öğrencileri, pek çok organın çevresindeki anatomik yapılarla olan bağlantısını anlamakta güçlük çekmektedir. Anatomi atlasları sadece 2 boyutlu (2B) statik görseller sunmaktadır. Ancak bunların etkisi, 3B dinamik görsellerle kıyaslandığı zaman yetersiz kalmaktadır. Günümüzde, kadavra eğitimine alternatif olarak ve bilgisayar yazılım/donanım dünyasındaki gelişmelere bağlı olarak dijital materyal kullanımı artmıştır. Ancak dijital medya kullanımı ve sanal platformlar oluşturma konusunda halen daha yapılması gereken pek çok yenilik mevcuttur. Önerdiğimiz platform, insan anatomi atlasının 3B gerçekçi bir yapısını sunmayı, bu yapıyı Sanal Gerçeklik ile birleştirmeyi ve en önemlisi öğrenmeyi oyunlaştırma ile maksimize etmeyi hedefler nitelikte ortaya çıkmıştır. Aynı zamanda geliştirdiğimiz web arayüzü sayesinde eğitmenler online veri girişi yapabilmekte ve sanal sınav oluşturabilmektedirler.

Anahtar Kelimeler: Oyunlaştırma, 2D-3D Medikal Modelleme, Medikal Animasyon, Sanal Gerçeklik, Anatomi Oyunları

1 Giriş

Klasik Tıp ve Anatomi eğitiminde, öğrenciler amfilerde gün boyu süren dersler almaktadır. Bu durum öğrencinin derse olan ilgisini azaltmakta ve öğrenciyi, dersi geçmeye dayalı bir düşünceye itmektedir. Ancak bu tutum, üst sınıflarda eklenen yeni dersler ve tıbbi bilgilerin ağırlığı altında öğrencilerin eski bilgilerini unutabilmesine sebebiyet vermektedir. Tıp Fakültelerinin fiziksel ve eğitim alt yapı sorunları kısa zamanda çözülebilecek problemler gibi görünmese de gerekli araştırma-geliştirme olanakları ve destekler ile çözülebilirler. Örneğin, erişkinlere yönelik ciddi oyun uygulamaları, sanal ve artırılmış gerçeklik uygulamaları, holografik uygulamalar, kadavra yerine geçecek simülatörler ve 3D yazıcılardan alınan özgün anatomik model çıktıları gibi en son teknoloji ürünleri, tıp öğrencisini ezberden uzaklaştırarak, konuları kalıcı bir şekilde öğrenmesine olanak sağlayabilir ([1], [2]). Aşağıda, tıpta teknolojik gelişmelerle ilgili yayınların ve programların bilgilerini paylaşacağız.

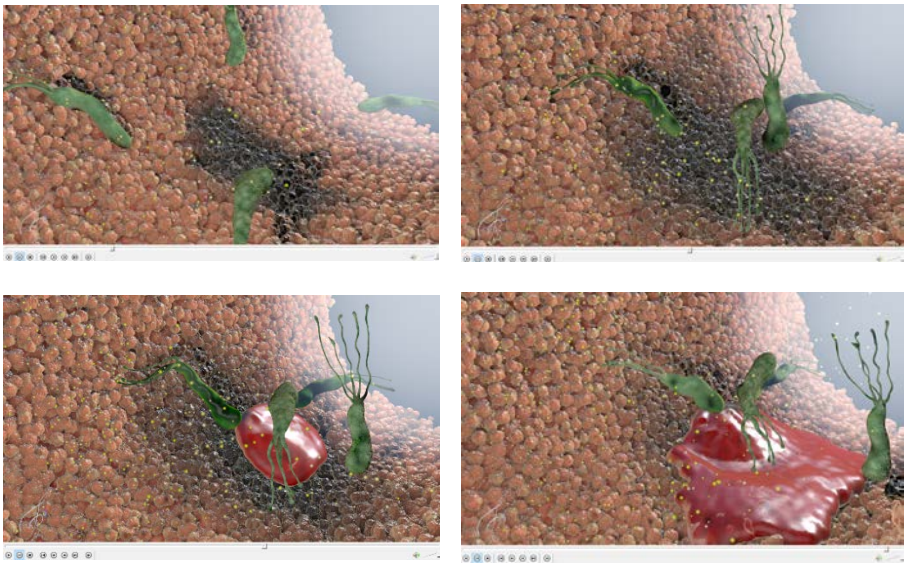

Şekil 1. Tarafımızca yapılan mide mukosası ve helikobakter modellerinin videosuna ait dört farklı saniyede alınmış görüntüler. Tüm videolar platformumuza entegre edilebilir durumdadır.

Modern teknolojinin gelişmesi ile birlikte sağlıkta bilgisayar uygumalarının kullanımı giderek hız kazanmıştır ve oyunlaştırma diğer alanlardaki kullanımı kadar tıp alanındaki kullanımı incelenmemiş olsa dahi dikkat çekici bir unsur olmayı sürdürmektedir. Oyunlaştırmanın, öğrenmedeki yerine ve önemine değinen çeşitli yayınlar mevcuttur ([3], [4], [5]) ancak tıpta bu konu halen daha açık bir araştırma alanıdır. Dijital oyunlaştırma, hiç şüphesiz 21. yüzyılda eğitimde kaçınılmaz bir öğe olarak varlığını sürdürecektir. Bu nedenle alan çalışmalarının hız kazanması kaçınılmazdır.

Tıpta sanal ve artırılmış gerçeklik kullanımı gitgide yaygınlaşmaktadır. Karmaşık bir anatomiye sahip olan vücut yapılarının ve bunlarla ilgili işlevlerin yada patolojilerin öğrenilmesi sanal ve artırılmış gerçeklik gibi multimedya teknolojileri ile daha kolaylaşmış bulunmaktadır. Bununla ilgili dönemsel olarak ilk yayınlardan biri Riva tarafından yapılmıştır [6]. Riva, tıpta sanal çevre oluşturmanın öneminden 15 sene önce bahsetmiştir. Al-Kalifav ve diğerleri [7], uygulamanın yeni yaygınlaşmaya başladığı dönemlerde ileri görüşlü bir şekilde sanal gerçekliğin tıbbi tanı ve eğitimde nasıl kullanılabileceğini yazmışlardır. O dönemde sonuca vardıklarında, anketlere katılan pek çok kişinin halen daha sanal gerçeklik teknolojisinin günümüz teknolojisi değil de gelecekte kullanılabilecek bir teknoloji olduğunu düşündüklerini belirtmişlerdir. Ancak 2018 senesine geldiğimizde sanal ve artırılmış gerçeklik teknolojisinin günümüz teknolojisi olması kaçınılmayacak bir gerçektir. İlerleyen senelerde bu konuda pek çok yayın ve survey çıkmıştır. Claudio ve Maddalena [8] yaptıkları survey'de 90'lı yıllardan bu yana tıbbi bilgisayar yaklaşımındaki gelişmeleri ve özellikle sanal gerçekliğin

tıpta kullanım tarihini ayrıntılarıyla yazmışlardır. Li ve diğerleri [9] yakın zamanda çıkardıkları yayınlarında sanal gerçekliğin özellikle cerrahi eğitimlerde, ağrı kontrolünde ve zihinsel hastalıkların tedavisinde ne şekilde kullanılabileceğini yazmışlardır. Bunun yanı sıra, artırılmış gerçeklik, sanal gerçekliğe göre daha yeni gelişmekte sayılsa da potansiyeli oldukça yüksektir. Zhu ve diğerleri [10] sağlık eğitiminde artırılmış gerçeklik uygulamaları ile ilgili bir yayın yaptıklarında halen daha AR için erken dönem olduğunu ama yüksek bir potansiyele sahip olduğunu vurgulamışlardır. Zielke ve diğerleri [11] tıp eğitiminde sanal hastalar yaratıp onlarla VR ve AR yöntemi ile nasıl etkileşim kurulabileceğini yazmışlardır. Hsieh ve Lee [12] ise henüz yakın zamanda yaptıkları yayınlarında aynı zamanda mixed reality (AR ve VR kombinasyonu)'nin tıbbi eğitimlerde nasıl kullanılacağından bahsetmişlerdir.

Tıp öğrencilerine anatomi öğretilmesi esnasında yaşanan sıkıntılar dünyada bazı çalışmaların gelişmesine sebep olmuştur. Örneğin, BioDigital [13] şirketi, anatomi öğretmek adına web, mobil ve AR uygulamalar geliştirmektedir. VisibleBody [14] benzer bir platform olup aynı zamanda animasyonlar ile platformu desteklemektedir. Aynı şekilde Hybrid [15] şirketi de, öğrencilerin patolojik kavramları daha rahat anlamaları adına medikal animasyonlar yapmakta, ör. akciğer kanserinde immunoterapi, felç riski önleme, zatüree nedir vb. animasyonlar, ve bunları sanal gerçeklik ile entegre etmektedir. Aynı zamanda çocuklar için artırılmış gerçeklik uygulamaları da vardır. Ek olarak, 3D4Medical's Complete Anatomy, [16], 3D4Medical şirketi tarafından yürütülen, ve geleneksel anatomi atlası kullanımını modernize etmeyi amaçlayan bir anatomi platformudur. Diğer platformlara benzer şekilde animasyon ve AR öğeleri barındırmaktadır ancak farklı şekilde çeşitli dersler eklemiştir. zSpace ise [17] bunların hepsine ek olarak hologram teknolojisi kullanmakta olup öğrencilere tamamen farklı bir öğrenme platformu sunmaktadır. Aynı zamanda bizim de gelecekte entegre etmek istediğimiz kuvvet geribildirimi (haptic force feedback) için de entegre bir sistem yaratmışlardır.

Oyun, öğrenmenin bir parçasıdır ve tıbbi eğitimlerde oyun öğeleri kullanmanın, öğrencilerin algıları açısından son derece önemli olduğuna inanmaktayız. Bu nedenle platformumuzda gerek quiz, gerek puzzle tarzında gerekse de daha kompleks 3B oyun öğeleri bulunmaktadır. Ve bu tarz oyunlar, ciddi oyun adını verdiğimiz alana hitap etmektedir. Burada önemli olan kullanıcı ara yüzünün kullanışlı olması ve herkese hitap etmesidir. Bazı anatomi araçlarında oyunlara rastlamak mümkündür. Örneğin, AnatomyLearning, gerek web tabanlı sürümü, gerek de mobil uygulaması ile kullanıcılarına anatomi öğretmeyi hedeflemektedir ve uygulama içinde quiz'ler vardır. Ancak kullanıcı arayüzündeki sıkıntılar nedeni ile quizlerin çözümü olabildiğince karmaşıktır ve açıklamalar yetersizdir [18]. AnatomyTool [19], Hollanda'da üretilen bir anatomi öğretme platformudur. Genellikle gerçek resimler ve kesitler üzerinden öğrencilere ders sunmayı hedeflemektedir. Bu nedenle öğrencilere ödev şeklinde quizler de sunulmaktadır. Her iki programın yukarıda bahsedilen platformlardan farkı, VR-AR entegre sistemler olmamalarıdır. Ayrıca quizler, tam anlamıyla oyun öğesi sayılamaz.

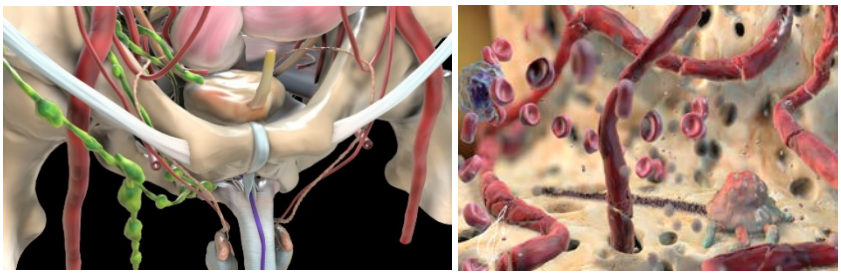

Şekil 2. Cinema4D ile ürettiğimiz ilk anatomik modeller.
Sol) Erkek genital organ
Sağ) Kemikte osteoklastik aktivite.

Bizim platformumuzda amacımız üç boyutlu (3B) daha kompleks ancak anlaşılır oyun öğeleri ile eğitimi desteklemektir, ör. 3B mide (bk. Şekil 1) içinde gezinti yapan oyuncu ülserli bölgeyi keşfedip onu iyileştirmek için neler yapması gerektiğine dair sorularla ve protokollerle karşılaşıp, bir protokol seçerek, orada yarattığımız 3B helikobakterler ile gerçek zamanlı savaşabilir durumdadır. Bu ve benzeri komplike oyun teması geliştirmek ve gerçekçi senaryolar yaratmak platformumuzun en temel unsuru olmuştur. Yarattığımız web arayüzü sayesinde eğitmenlerin gerek quiz gibi yazı tabanlı, gerek ise komplike 3B ciddi oyun öğeleri içeren sınavlar yaratmaları da mümkündür. Diğer platformlardaki ciddi eksiklerden birisi, kompleks oyun sistemleri ile yaratılmış sınavlarının olmaması ve bu konuda eğitim kalitesini ölçme ve değerlendirme sistemlerinin bulunmayışıdır. Bu projedeki temel amacımız oyunlaştırmanın ve çoklu medya kullanımının uzun vadede tıptaki başarı oranlarına etkisi üzerine analizler yapabilmektir.

2 Yöntem

2.1 2B-3B Modelleme ve Animasyon

Piyasada üç boyutlu modelleme yapılabilecek pek çok araç mevcuttur. Bunların bazıları özellikle çizgi film, reklam ya da oyun içi modelleme yapımında, kimileri film yapımında, kimileri mimari, kimileri tıbbi çizim modellerinde uygundur. Elbette tüm bu platformları oluştururken, yaratılacak olan üç boyutlu modellerin gerçeğe uygun olması gerekmektedir. Spesifik olarak tıbbi çizim amacı ile oluşturulan bazı şirketler mevcuttur. Örneğin Materialise şirketi Mimics ile (bk. [20]) üstün kaliteli 3B tıbbi modeller yaratmak için kullanılabilen profesyonel bir araçtır. Ancak, organik model yapımına olanak veren herhangi bir 3B modelleme aracı da amacımıza hizmet edebilmektedir. Biz de bu noktada organik modellerin diğer 3B modelleme araçlarına kıyasla daha kaliteli bir şekilde yapılabildiğine inandığımız, tıbbi animasyon konusunda sağlam bir altyapı kurulmasına olanak veren Cinema4D kullanmaya karar vermiş bulunuyoruz (bk. Şekil 2).

Şekil 3. Platformumuza entegre ettiğimiz dicom-dir film dosyalarını, kaydırıcı (slider) yardımıyla hızlıca gözlemleyebiliyoruz.

Modellerimiz, tüm organların hem makroskopik hem de mikroskobik yapıları ile ilgili ve son tıbbi bilgilerin ışığında kapsamlı bir şekilde oluşturulmaktadır. Modellemelerin tamamlanmasından sonra elde edilen dijital ürünlerin gerçek hayatta olduğu kadar doğal bir şekilde dokulandırılması, kabartılı, deforme ya da parlak görüntüde olabilmesi için bir dizi işlem uygulanmaktadır. Daha sonra en optimal görüntüleri alabilmek için ideal ortam ışıklandırmaları yapılmaktadır. Mevcut modeller sonrasında gerekli görülürse animasyona da çevrilmekte ve platformumuza entegre edilmektedir (bk. Şekil 1). Modelleme için diğer bir yol ise CT, MRI ve PET-Scanning gibi tıbbi görüntüleme cihazlarından alınan hasta yada kadavralara ait olan ve dicom.dir formatında olan dijital verilerin istendiği takdirde üç boyuta geçirilmesidir. Ancak projemizde kendi oluşturduğumuz 3B modeller kullanmamız sebebiyle, dicom-dir formatındaki 2B görselleri yalnızca hızlı görüntüleme ve platformu zenginleştime amacıyla entegre etmiş bulunuyoruz (bk. Şekil 3).

Bu noktada önemli bir husustan bahsetmekte fayda görüyoruz. Ufak bir hata, içinde yaşadığımız bilişim dünyasında hatanın bir anda milyonlarca kullanıcıya ulaşmasına neden olmaktadır. Böyle bir olumsuzluğa meydan vermemek için, yaratılan dijital tasarımların muhakkak meslek profesyonelleri tarafından incelenmesi gerekmektedir. Bu projede tüm modellemeler ve animasyonlar, bir tıp profesörü anatomi uzmanı tarafından yapılmaktadır.

2.2 Oyun Motoru Entegrasyonu ve Oyunlaştırma

Günümüzde oyun geliştirmek için pek çok oyun motoru kullanılmaktadır. Bunların çoğu paralı araçlar olmakla beraber, pazarda yer alan tamamen ücretsiz ya da kısmen ücretsiz (ücretli ve limitli ücretsiz versiyonları olan) başarılı oyun motorları mevcuttur. Öğrenme eğrisi diğerlerine göre daha kolay olan, kullanışlı bir kullanıcı arayüzü ve programlama altyapısı sunan ve halihazırda pek çok profesyonel tarafından da kullanılan tamamen ücretsiz Unity oyun motorunu bu sebeple sanal platform oluşturmak için tercih ediyoruz. Unity yalnızca oyun geliştirmek için değil, aynı zamanda barındırdığı scenegraph (sahne hiyerarşik veritabanı) sayesinde etkili sanal platformlar oluşturmak için de sıkça tercih edilen bir araçtır. Şekil 4'te, Cinema 4D'de

ürettiğimiz glomus caroticum tümörü modelinin Unity'de yaratmış olduğumuz ilk sanal sahnemize aktarılması ve Şekil 4-d'de Unity oyun motoru kullanarak hazırlamış olduğumuz ilk menü örneğimiz sunulmuştur.

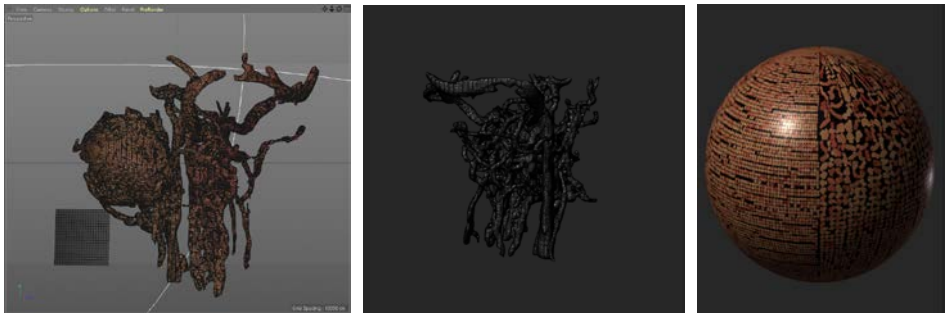

a b c

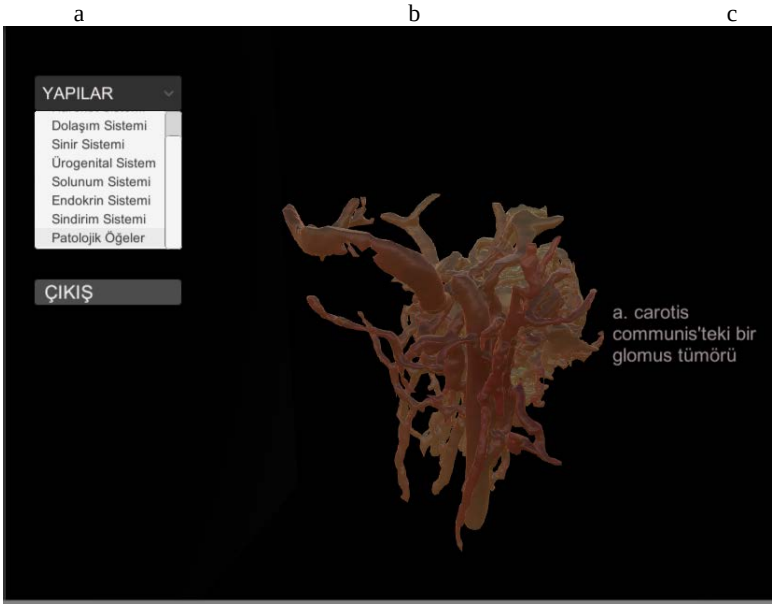

d

Şekil 4. Cinema 4D'de ürettiğimiz glomus caroticum tümör modelinin Unity'de yaratmış olduğumuz ilk sanal sahnemize aktarılması.
a) Cinema 4D model **b)** Unity'e atılan model
c) Unity'e atılan kaplama **d)** Yapılar seçeneği, alınan modelin Unity ortamında görünüşü ve gerekli bilgilendirme

Hazırlamış olduğumuz platformda, üç boyutlu modelleri görebildiğimiz, yakından inceleme olanağı tanıyabildiğimiz ve ayrıca varsa ilgili animasyonları oynatabildiğimiz gibi aynı zamanda onlarla etkileşime girme olanağı da sağlamaktayız. Örneğin Şekil

5’te görüldüğü üzere, kafatası ile etkileşime geçmek isteyen kullanıcı kafatasını patlatma efekti kullanarak parçalara ayırabilir, istediği kısım üzerine basabilir, renklendirebilir ve hakkında bilgi alabilir.

Şekil 5. Kafatası patlama efekti ve bilgilendirme

Şekil 6’da ise quiz sistemimiz gösterilmektedir. Burada kullanıcı sorulan soru karşılığında doğru yapıyı seçerek ilerler. Hatalı cevap verirse ikaz alır. İpucu görmek isterse ise İpucu tuşuna basar, ilgili yazılı yada 2B/3B görsel ipucu ile karşılaşır. Bu görsel ipucu bir animasyon, 3B model yada 2B resim olabilir.

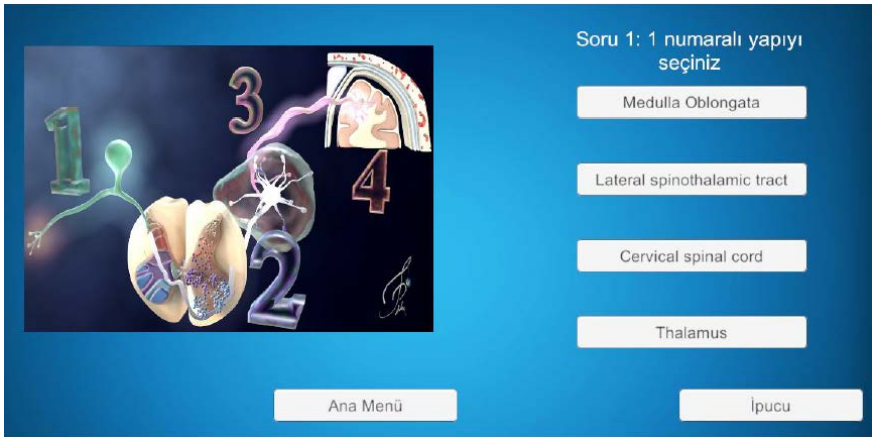

Şekil 6. Quiz sistemi

Sanal Gerçeklik Entegrasyonu

Giriş Bölümü’nde bahsetmiş olduğumuz gibi karmaşık bir anatomiye sahip olan vücut yapılarının ve bunlarla ilgili işlevlerin yada patolojilerin öğrenilmesi kolay değildir. Ancak Sanal Gerçeklik öğenme sürecini hızlandıran ve pekiştiren bir teknolojidir ve bu teknolojinin, anatomi öğrenimi sırasında da oldukça etkili olacağına inanmaktayız. Bu sebeple platformumuza Sanal Gerçeklik entegre etmeyi yerinde bulduk. Burada tercih ettiğimiz teknoloji HTC Vive olup, Unity’de açmış olduğumuz bir 3B kalp modelini

kaplama ve normal haritaları ile birlikte sanal gerçeklik ile gözlemleyebilme deneyimimizi Şekil 7'de görebilirsiniz.

Şekil 7. Sanal Gerçeklik Entegrasyonu. **Sol)** Unity içinde açtığımız 3B kalp modeli **Sağ)** Grafik laboratuvarımızda kalp modelinin sanal gerçeklik gözlüğü ile gözlenmesi

Bu noktada kullanıcı arayüzünün kullanışlı bir şekilde nasıl oluşturulacağı ve 2B/3B medyanın Unity'ye nasıl aktarılacağı sorusu gündeme gelmektedir. Bunun için platformumuza entegre ettiğimiz WEB arayüzü ile ilgili detaylar bir sonraki kısımda anlatılmıştır.

2.3 WEB Arayüzü

Geliştirdiğimiz platformumuz WEB uygulamamız üzerinden erişime açıktır (bk Şekil 8.). WEB arayüzümüz üzerinden video dahil tüm medyaların girişi ve quiz sistemi oluşturma menüsü hazırlanmıştır. Şu anda web arayüzü kullanma yetkisi yalnızca Admin'de yani geliştirici ve eğitmendedir. Eğitmen, arayüz üzerinden sistemlere erişebilir (ör. Dolaşım, Hareket, vb.), quiz ekleyebilir, video ve çeşitli görseller yükleyebilir, ve yüklediklerini konulara ayırıp anahtar kelimeler oluşturarak onlara daha kolay erişebilir.

WEB arayüzü geliştirmek için kullandığımız teknolojileri şu şekilde sıralayabiliriz:

- React.js – Zengin arayüz temaları oluştırmayı sağlayan bir Javascript kütüphanesidir.
- Cascade Style Sheet (CSS) – HTML kodunun son kullanıcıya göründüğü halidir. Kullanışlı ve basit arayüzler sağlar.
- Hyper Text Markup Language (HTML) – Web sitelerinin yapısını oluşturur.
- JSX – React.js'in, geliştiricilerin HTML kodunu Render fonksiyonuna gömmelerini sağlayan ve böylece web ayfalarını React birimlerinin içinde gösterilmesine olanak tanıyan bir söz dizimi uzantısıdır.
- Visual Studio Code – Javascript kodumuzu geliştirdiğimiz text editörüdür.

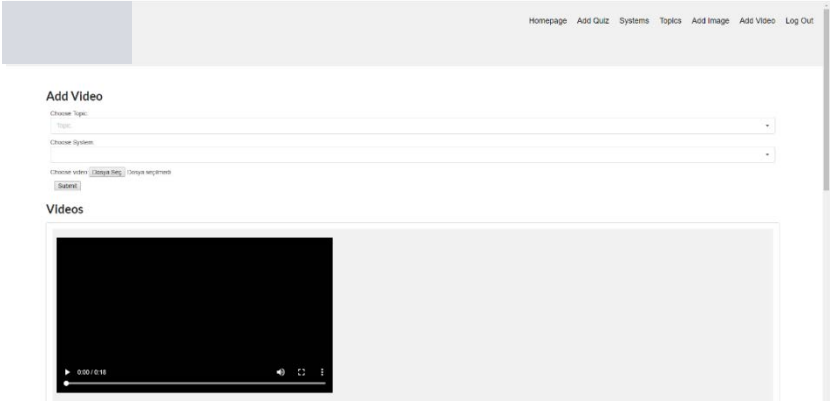

Şekil 8. WEB arayüzümüz

Web Server için için kullandığımız teknolojileri de şu şekilde sıralayabiliriz:

- Java - Nesne-tabanlı programlama dilidir
- Spring Boot - WEB sunucu yazılım iskeleti
- Java Persistence Api (JPA) – Veritabanı için gereklidir
- JetBrains Intellij Idea – Geliştirme Ortamı.

3 Tartışma ve Sonuç

Platformumuzun ilk geliştirilme aşaması sonlanmıştır. Buna göre oyun mekanikleri, quiz mekanikleri, kullanıcı arayüzü, kompleks veri yapıları, WEB sunucu ve veritabanı testleri yapılmış ve hepsinde sonuç pozitif çıkmıştır. Buna göre platformumuz kullanıma hazırdır.

Bir anatomi uzmanı tarafından pilot çalışmaya tabii tutulan platformumuz için kısa vadede yapılacak ilk önemli iş, bir öğrenci grubunun platformumuzu denemesidir. Akabinde, deneme grubu ve deneme yapmayan kontrol grubu üzerinde bir senenin ardından yapılacak ilk sınav ve takribi analizlerin, oyunlaştırmanın anatomi eğitimine etkisi üzerinde bizlere değerli bilgiler aktaracağına inanıyoruz. Yapılması planlanan pilot çalışmalar için gerekli Etik Kurul kararı alınmıştır (TED Üniversitesi İnsan Araştırmaları Etik Kurulu 14.05.2019 ve 2019/34 sayılı karar).

Eş zamanlı olarak sanal sınıf ve sanal sınav açmayı mümkün hale getirmek planlanan diğer bir aşamadır. Böylece öğrencilerin oyunlardaki başarılarının eğitmenler ile web üzerinden otomatik olarak paylaşılması ve analitik tutulması da projemizin önemli bir parçası olacaktır.

Referanslar

1. Azer, S.A., Azer S.: 3D Anatomy Models and Impact on Learning: A Review of the

Quality of the Literature. Health Professions Education 2 (2), 80-98 (2016).
2. Aslan, R., Erdoğan, S.: 21. Yüzyılda Hekimlik Eğitimi: Sanal Gerçeklik, Arttırılmış Gerçeklik, hologram., Kocatepe Vet J. 10 (3): 204-212 (2017).
3. Brull, S, Finlayson, S.:Importance of Gamification in Increasing Learning. The Journal of Continuing Education in Nursing · Vol 47, No 8 (2016)
4. Marugappan, V., Bhattacharya, D. Kim, Th.: Research Study on Significance of Gamification Learning and i- Campus Using Internet of Things Technology-Enabled Infrastructure. (06.04.2018).
5. Huang, W.HY, Soman, D. :A Practitioner's Guide To Gamification Of Education. Research report, (10 December, 2013).
6. Riva, G. Applications of Virtual Environments in Medicine", Methods Inf Med. 2003; 42(5):524-34 (2003).
7. Al-khalifah, A.H., McCrindle, R.J., Sharkey, P.M., Alexandrov, V.N.: Using Virtaul Reality for Medical Diagnosis, Training and Education, Proc. 6th Intl. Conf. Disability, Virtual Reality & Assoc. Tech., Esbjerg, Denmark (2006).
8. Claudio, P., Maddalena, P. 2014. "Overview: Virtual Reality in Medicine". Journal of Virtual Worlds Research, 7(1), 1-34.
9. Li, L., Yu, F., Shi, D., Shi, J., Tian, Z., Yang, J., Wang, X., Jiang, Q.:Application of virtual reality technology in clinical medicine. American Journal of Translational Research, 9(9), 3867–3880 (2017).
10. Zhu, E., Hadadgar, A., Masiello, I., Zary, N. : Augmented Reality in Healthcare Education: an Integrative Review, PeerJ 2:e469 (2014)
11. Zielke, M.A., Zakhidov, D., Hardee, G., Evans, L., Lenox, S., Orr, N., Fino, D., Mathialagan, G. : Developing Virtual Patients with VR/AR for a natural user interface in medical teaching, IEEE 5th International Conference on Serious Games and Applications for Health (SeGAH), 2-4 April 2017 (2017).
12. Hsieh, MC., Lee, JJ.: Preliminary Study of VR and AR Applications in Medical and Healthcare Education, Nurs Health Stud. 3(1):1 (2018).
13. BioDigital. The World's First Human Visualization Platform". https://www.biodigital.com/. Son erişim tarihi: 28 Şubat 2019.
14. Visible Body. VisibleBody Platform. https://www.visiblebody.com. Son erişim tarihi: 28 Ağustos 2018.
15. HybridMedical, Hybrid Medical Animation. https://www.hybridmedicalanimation.com. Son erişim tarihi: 02 Mart 2019.
16. 3D4Medical. Complete Anatomy Platform. https://3d4medical.com/apps/complete-anatomy. Son erişim tarihi: 23 Şubat 2019.
17. zSpace. zSpace for Medical Learning. https://zspace.com/medical-learning. Son erişim tarihi: 05 Mart 2019.
18. AnatomyLearning. AnatomyLearning Platform. http://anatomylearning.com/en/. Son erişim tarihi: 23 Şubat 2019.
19. AnatomyTOOL. Topic Oriented Open Learning Platform. http://www.anatomytool.org/about. Son erişim tarihi: 23 Şubat 2019.
20. Materialise. Mimics Platform. https://www.materialise.com/en/medical/software/mimics. Son erişim tarihi: 02 Mart 2019.

Challenges of Big Data in Machine Learning Based MicroRNA Analysis

Müşerref Duygu Saçar Demirci[1]

[1] Abdullah Gül University, Bioinformatics, Kayseri, 38080, Turkey
duygu.sacar@agu.edu.tr

Abstract.

MicroRNAs (miRNAs) are small, single-stranded, non-coding RNAs of about 22 nucleotides in length, which control gene expression at the posttranscriptional level through translational inhibition, degradation, adenylation, or destabilization of their target mRNAs. Although thousands of miRNAs have been identified in hundreds of species, many more still remain undetermined. Therefore, detection of new miRNA genes is an important step for understanding miRNA mediated posttranscriptional regulation mechanisms. Since biological methods are limited in their capacity to identify rare miRNAs, the construction of sophisticated computational tools for detection of miRNA candidates *in silico*, has become a widely used approach. Two main approaches have been employed so far; the first one making use of homology information while the other is based in machine learning (ML). While there are some examples where unsupervised ML methodologies are used for miRNA target prediction, ML for miRNA gene prediction is almost exclusively based on supervised learning. Due to the fact that majority of pre-miRNA prediction tools are based on supervised ML, they also suffer from the challenges of ML including curse of dimensionality and data quality. In this work, the aim is listing such challenges that would be affecting miRNA research.

Keywords: Bioinformatics, Machine Learning, MicroRNA, Big Data.

MicroRNAs (miRNA) are one of the members of small, non-coding RNAs that are single-stranded and around 22 nucleotides (nt) in length. They take part in posttranscriptional regulation of gene expression by using either translational inhibition or destabilization of the target mRNAs [1,2]. Various organisms ranging from viruses to higher eukaryotes use miRNAs for regulating essential and numerous processes. Based on the estimations, miRNAs seem to be controlling activities of about 30% of all protein coding genes in mammals [2].

Moreover, it has been showed that miRNAs' action is involved in many human diseases such as cancer and neurodegenerative diseases and still many more are under investigation [3].

Since experimental detection of miRNAs involves laborious steps and tends to be costly, computational miRNA prediction has become a fundamental element of miRNA studies. In general there are two main strategies for bioinformatics based miRNA detection. The first one is homology-based methods, which is one of the main and straightforward approaches, using known miRNAs to search for their homologs in other organisms. While the system works well for widely conserved miRNAs, it is limited in terms of species-specific miRNAs.

Nowadays, majority of tools for pre-miRNA prediction is based on classification, which is a supervised machine learning (ML) approach. Classifiers like support vector machine (SVM), naïve Bayes (NB), random forest (RF), and many more have been applied to obtain models for pre-miRNA detection [4].

ML is a procedure that is highly influenced by different parameters like the quality of training and testing datasets, feature selection method, and the choice of classification algorithm. The overall model performance is affected by each of these elements. However, the most crucial ones are the data sets and feature selection process since data quality has a big influence on the accuracy of the process [5] and calculation of some features takes a lot of time and computational power [6,7]. While using big data for ML, certain big data challenges also need to be taken into consideration. Some of these are more important in the case of miRNA prediction analysis:

1. Data growth.
2. Integrating related data from various sources.
3. Extracting knowledge from data in a timely manner.
4. Validating data.

References

1. Piast, M., Kustrzeba-Wojcicka, I., Matusiewicz, M., and Banas, T.: Molecular evolution of enolase. Acta Biochimica Polonica 52(2), 507–513 (2005).
2. Filipowicz,W., Bhattacharyya, SN., and Sonenberg, N. : Mechanisms of posttranscriptional regulation by microRNAs: are the answers in sight? Nature reviews. Genetics 9(2), 102–14 (2008).
3. Li, Y., Qiu, C., Tu, J., Geng, B., Yang, J., Jiang, T., and Cui, Q.: HMDD v2.0: A database for experimentally supported human microRNA and disease associations. Nucleic Acids Research 42(D1), D1070–4 (2014).
4. Saçar Demirci, MD., Baumbach, J., Allmer, J.: On the performance of pre-microRNA detection algorithms. Nature Communications 8(1), 330 (2017).
5. Saçar, MD., Allmer, J.: Data mining for microrna gene prediction: On the impact of class imbalance and feature number for microrna gene prediction. 8th International Symposium on Health Informatics and Bioinformatics 1–6 IEEE, (2013).
6. Lindow, M., Gorodkin, J.: Principles and limitations of computational microRNA gene and target finding. DNA and cell biology 26(5), 339–51, (2007).
7. Ding, J., Zhou, S., Guan, J.: MiRenSVM: towards better prediction of microRNA precursors using an ensemble SVM classifier with multi-loop features. BMC Bioinformatics 11, S11 (2010).

MULTI-OMICS INTEGRATION WITH BAYESIAN NETWORKS

İdil Yet[1]

[1] Department of Bioinformatics, Graduate School of Health Sciences, Hacettepe University, Ankara, TURKEY

Abstract: Epigenetic mechanisms and gene expression levels have both been shown to play a role in susceptibility for complex human disease. Here, I analysed the association between genomics and transcriptomics and epigenetic datasets and combined the data to identify connections between these levels of biological data at genetic variants linked to disease. I fit Bayesian networks to the peak trait-GWAS, trait-expression, and trait-DMPs results and pair-wise associations, to gain more insight into disease susceptibility and progression. I initially explored the genetic basis of gene expression and epigenetic datasets on their own. I subsequently combined these results to better understand the relationship between the genetic basis of epigenomics and gene expression in the context of genetic variants associated with complex diseases. The findings show that specific genetic susceptibility variants for complex diseases can also impact epigenetic and gene expression levels, and can help improve our understanding of the disease etiology.

Keywords: Bayesian Networks, Multi-Omics, Epigenomics, Transcriptomics, Genomics

1 Introduction

The main aim of this research is to understand the biological mechanisms involved in complex diseases susceptibility and progression, by linking DNA methylation and gene expression to disease [1].
Multiple GWAS have been conducted to explore genetic influences on complex diseases, identifying several variants to date [2]. Finally, complex disease-related differentially methylated regions (DMRs) and gene expression levels have also been identified.
The research aim was to attempt to infer causality in trait by fitting Bayesian networks to the peak trait-GWAS, trait-expression, and trait-DMP results and their pair-wise associations, to gain more insight into disease susceptibility and progression.

2 Methods and Results

Bayesian Networks (BNs) are graphical probabilistic models that are able to represent joint probability distributions compactly in a factorized way [3, 4]. A BN consists of a graphical structure and a set of parameters. The graphical structure of a BN is a directed acyclic graph (DAG) that consists of nodes representing variables and directed edges representing the relations between those variables. The parameters of a BN represent the conditional probability distributions between the variables that are directly connected by an edge.

In this study, I build three BN structure for the alternative causal relations, I estimated the parameters of these structures from the data and finally I examined the compatibility of these structures with the data by using the AIC Score.

2.1 Fitting Bayesian Networks

To test the networks I selected three datasets (genetic, methylation, and gene expression) that were normalized to calculate the relative frequencies of the inferred best network. Altogether, the merged normalized dataset for these BN analyses contained 25 individuals [5].

I built three BN structures representing the alternative hypotheses of the causal relations between SNP, gene expression (E) and methylation (MT). The first BN structure assumes that there is a causal relation from SNP to both MT and E, and thus MT and E are independent of each other given SNP (INDEP). The second BN structure assumes there is a causal relation from SNP to E, and from E to MT (SEMt). The third BN structure assumes there is a causal relation from SNP to MT, and from

MT to E (SMtE). The parameters of these networks were estimated by using the maximum likelihood approach. Afterwards, I examined the compatibility of these structures with the data by using the AIC score. I used the Akaike Information Criterion (AIC) score (AIC = 2k-2ln(L), where k is the number of parameters and L is the maximum likelihood to compare our networks. To compare the goodness of fit of one network to another, I used the relative likelihood of one network against the other following previous work [1, 6]. If I have two networks, N1 and N2 and AIC(N1) ≤ AIC(N2), then the relative likelihood of N2 with respect to N1 is defined as: exp((AIC(N1)–AIC(N2))/2). I kept only networks where the best model was at least ten times more likely than the second best model. The bnlearn package in R was used to build and calculate the BN models [7].

I used BN to test which of the three possible models best suit each set of variables. After fitting all the models at three-way associations, there were 10 models where the best model was at least ten times more likely than the second best model.

3 Discussion and Conclusion

In this study, I first explored the association of gene expression and epigenetic data and one of the complex diseases. Multiple signals were identified to associate with disease at both the gene expression and epigenetic levels. The availability of different levels of "-omics" data allowed me to explore the relationship between disease-associated "-omics" profiles, specifically for genetic variation, methylation and gene expression.

After restricting results to at least nominally significant associations from three-way associations, I obtained a list of three-way associations to explore further in a BN context. I detected 10 cases of three-way associations where either genetically driven DNA methylation levels impact gene expression profiles, or genetically driven gene expression traits impact DNA methylation levels.

Overall, these results suggest that the effects of DNA methylation can be both active on gene expression levels, and passive, by being a consequence for gene expression levels. This study shows the potential of integrating other "-omics" data for complex diseases.

References

1. Gutierrez-Arcelus M, Lappalainen T, Montgomery SB, Buil A, Ongen H, Yurovsky A et al. Passive and active DNA methylation and the interplay with genetic variation in gene regulation. Elife. 2013;2:e00523. doi:10.7554/eLife.00523.

2. Kulminski AM, Huang J, Loika Y, Arbeev KG, Bagley O, Yashkin A et al. Strong impact of natural-selection-free heterogeneity in genetics of age-related phenotypes. Aging (Albany NY). 2018;10(3):492-514. doi:10.18632/aging.101407.

3. Pearl J. Probabilistic reasoning in intelligent systems: networks of plausible inference. Morgan Kaufmann; 1988.

4. Koller D, Friedman N. Probabilistic graphical models: principles and techniques. MIT press; 2009.

5. Hou Y, Guo H, Cao C, Li X, Hu B, Zhu P et al. Single-cell triple omics sequencing reveals genetic, epigenetic, and transcriptomic heterogeneity in hepatocellular carcinomas. Cell Res. 2016;26(3):304-19. doi:10.1038/cr.2016.23.

6. Bryois J, Buil A, Evans DM, Kemp JP, Montgomery SB, Conrad DF et al. Cis and trans effects of human genomic variants on gene expression. PLoS Genet. 2014;10(7):e1004461. doi:10.1371/journal.pgen.1004461.

7. Scutari M. Learning Bayesian networks with the bnlearn R package. arXiv preprint arXiv:09083817. 2009.

Kolorektal Kanser Histolojik Doku Görüntülerinde Veri Ön İşleme Sonrasında Öznitelik Seçiminin Sınıflandırma Performansına Etkisi

Mert Demirarslan[1], Yüksel Özkan[1], Aslı Suner[1]

[1] Biyoistatistik ve Tıbbi Bilişim Anabilim Dalı, Tıp Fakültesi, Ege Üniversitesi, İzmir, Türkiye

The Effect of Feature Selection on Classification Performance after Data Pre-processing in Colorectal Cancer Histological Tissue Images

Abstract. Today, colorectal cancer is the sixth among cancer types seen in both men and women, and the third in cancer-related deaths, and it is a serious disorder that accounts for about 15% of other types of cancer. In 2018, the American Institute for Cancer Research reported that there are 1.8 million colorectal cancer patients in the world. Since algorithms used in the diagnosis of diseases should be fast and practical, some of the classical methods used in classification are inadequate. Therefore, artificial intelligence methods are especially preferred for accurate classification of disease diagnosis. In this study, numerical data of histological images of tissues of colorectal cancer patients downloaded from Kaggle database were used. In this study, it was aimed to improve the classification performances by performing data pre-processing and feature selection to histological tissue images with low classification performance. In the first stage of the study, data were pre-processed for class noise and class imbalance problems. Then the performance of Adaboost Bagging, Logitboost, Random Forest, MultiboostAB and Decorate classification algorithms were calculated. In the second stage, the algorithms' performances were recalculated after the feature selection was performed to the processed data set using filter, embedded and wrapper methods. The performances of the algorithms were evaluated with accuracy, sensitivity, specificity, precision, recall, F-measure and Kappa measurement metrics, and the run times were recorded. Finally, the algorithm with the highest performance and the fastest running was decided. WEKA 3.9.3 program was used in all statistical analyses. The most successful algorithm after data pre-processing was Logitboost with 93% accuracy; in the CfsSubsetEval filtering method used for attribute , the Decorate algorithm had 100% accurate. In the first stage, Random Forest was the fastest algorithm, whereas in the second stage, the embedded method gave the best results. As a result, the application of data preprocessing and feature selection methods improves the classification performance and provides efficiency in decision-making in terms of time and cost.

Keywords: Colorectal Cancer, Ensemble Learning, Class Noise, Class Imbalance, Attribute Selection,

Özet. Günümüzde kolorektal kanser, hem erkeklerde hem de kadınlarda görülen kanser türleri içerisinde altıncı, kanserden kaynaklı ölümlerde ise üçüncü sırada yer alan ve diğer kanser türlerinin yaklaşık %15'ini oluşturan ciddi bir rahatsızlıktır. Amerikan Kanser Araştırmaları Enstitüsü, 2018 yılında dünyada toplam 1,8 milyon kolorektal kanser hastası olduğunu belirtmiştir. Hastalık tanısında kullanılan algoritmaların hızlı ve pratik olması istendiğinden, sınıflandırma için tercih edilen bazı klasik yöntemler yetersiz kalmaktadır. Bu nedenle, yapay zekâ yöntemleri özellikle hastalık tanısının doğru sınıflandırılmasında tercih edilmektedir. Bu çalışmada, Kaggle veri tabanından kolorektal kanser hastalarının dokularına ait histolojik görüntülerin sayısal olarak elde edilmiş verileri kullanılmıştır. Çalışmada sınıflandırma performansı düşük olan histolojik doku görüntülerine veri ön işleme ve öznitelik seçimi yapılarak sınıflandırma performanslarının arttırılması amaçlanmıştır. Çalışmanın ilk aşamasında, sınıf gürültüsü ve sınıf dengesizliği problemleri için veri ön işleme yapılarak; Adaboost Bagging, Logitboost, Random Forest, MultiboostAB ve Decorate sınıflandırma algoritmalarının performansları hesaplanmıştır. İkinci aşamada, işlenmiş veri setine filtreleme, gömülü ve sarmal yöntemler kullanılarak öznitelik seçimi yapıldıktan sonra algoritmaların performansları yeniden hesaplanmıştır. Doğruluk, hassaslık, seçicilik, kesinlik, duyarlılık, F-ölçütü ve Kappa ölçüm metrikleriyle algoritmaların performansları değerlendirilmiş ve çalışma süreleri kaydedilmiştir. Son olarak, en yüksek performansa sahip olan ve en hızlı çalışan algoritmaya karar verilmiştir. Tüm istatistiksel analizlerde WEKA 3.9.3 programı kullanılmıştır. Veri ön işleme sonrası en başarılı algoritma %93 doğruluk oranıyla Logitboost iken; öznitelik seçiminde kullanılan CfsSubsetEval filtreleme yönteminde ise %100 doğruluk oranıyla Decorate algoritmasıdır. İlk aşamada en hızlı çalışan algoritma Random Forest iken, ikinci aşamada gömülü yöntem en iyi sonucu vermiştir. Sonuç olarak veri ön işleme ve öznitelik seçim yöntemlerinin uygulanması sınıflandırma performansını artırırken, zaman ve maliyet açısından da karar vermede etkinlik sağlamaktadır.

Anahtar Kelime: Kolorektal Kanser, Sınıf Gürültüsü, Sınıf Dengesizliği, Öznitelik Seçimi, Topluluk Öğrenme.

1 Giriş

Günümüzde hızla yaygınlaşan kanser hastalığı sonucunda erken teşhisin önemi arttığından, hekimlerin hızlı ve doğru karar vermesine yardımcı olacak yapay zeka tekniklerine başvurulmaktadır. Mevcut makine öğrenmesi yöntemleri sağlık alanında büyük verilere ait tanımlanmamış ilişkilerin ve gizli örüntülerin ortaya çıkarılmasında yaygın şekilde kullanılmaktadır [1]. Büyük veriler işlenirken doğru ve anlamlı kararlara ulaşmak için bazı veri ön işleme tekniklerine başvurulmaktadır. Bu çalışmada kolorektal kanser doku görüntülerinde [2,3] tıbbi tanıda uzman kararına daha verimli bir şekilde yardımcı olmak için, veri ön işleme teknikleri ve makine öğrenmesi yöntemlerinden topluluk öğrenme algoritmaları kullanılarak tanı koyma sürecinin hızlandırılıp, zaman ve maliyet kaybının azaltılması amaçlanmıştır [4].

2 Yöntem

Çalışmada Kaggle makine öğrenmesi veri tabanından, kolorektal kanser hastalarının dokularına ait histolojik görüntülerin sayısal olarak elde edilmiş verileri kullanılmıştır [2,5]. İlk aşamada, sınıf gürültüsü ve sınıf dengesizliği problemleri için veri ön işleme yapılarak; Adaboost Bagging, Logitboost, Random Forest, MultiboostAB ve Decorate sınıflandırma algoritmalarının performansları hesaplanmıştır. İkinci aşamada, işlenmiş veri setine filtreleme, gömülü ve sarmal yöntemler kullanılarak öznitelik seçimi yapıldıktan sonra algoritmaların performansları yeniden hesaplanmıştır [1,6]. Doğruluk, duyarlılık/hassaslık, seçicilik, kesinlik, F-ölçütü ve Kappa ölçüm metrikleriyle algoritmaların performansları değerlendirilmiş ve çalışma süreleri kaydedilmiştir. Son olarak, en yüksek performansa sahip olan ve en hızlı çalışan algoritmaya karar verilmiştir. Tüm istatistiksel analizlerde WEKA 3.9.3 programı ve macOS Mojave 1.8 Ghz i5 kullanılmıştır.

3 Bulgular

Kolorektal kanser veri setinde örneklem sayısı 64 hasta (50 kanser değil+14 kanser) iken, öznitelik sayısı 4097 ve sınıf sayısı 2 (kanser/kanser değil) olarak belirtilmiştir. Tablo 1'e bakıldığında, veri ön işleme ve öznitelik seçimi yapıldıktan sonra alt boyutlu verinin sınıflandırma performansının, ön işlemsiz verinin sınıflandırma performansına göre doğruluk ve Kappa ölçüm metrikleri açısından arttığı görülmüştür. Filtreleme yönteminden elde edilen veride, tüm kriterler açısından en yüksek performans gösteren Decorate algoritmasıdır. Gömülü yöntem kullanıldığında en başarılı algoritma tüm kriterler için Decorate algoritması iken, sarmal yöntemlerde en güçlü algoritma Random Forest ve Decorate olmuştur.

Tablo1: Ön işlemli verilerin öznitelik seçimi sonrası sınıflandırma performansı kıyaslanması

Durum	Algoritma	ACC	TP	FP	Pre	Rec	F	Kappa
Ön İşlemsiz	AdaBoost	0.72	0.72	0.72	-	0.72	-	0
	Bagging	0.72	0.72	0.72	-	0.72	-	0
	LogitBoost	0.77	0.77	0.60	0.82	0.77	0.70	0.22
	Random Forest	0.72	0.72	0.72	-	0.72	-	0
	MultiBoostAB	0.72	0.72	0.72	-	0.72	-	0
	Decorate	0.72	0.62	0.68	0.72	0.72	0.67	0.13
Ön İşlemli	AdaBoost	0.87	0.87	0.13	0.87	0.87	0.87	0.85
	Bagging	0.87	0.87	0.13	0.87	0.87	0.87	0.75
	LogitBoost	0.93	0.93	0.07	0.93	0.93	0.93	0.87
	Random Forest	0.90	0.10	0.90	0.90	0.90	0.90	0.81
	MultiBoostAB	0.75	0.75	0.25	0.75	0.75	0.75	0.50
	Decorate	0.90	0.90	0.10	0.90	0.90	0.90	0.81
Filtreleme	AdaBoost	0.96	0.96	0.96	0.04	0.96	0.96	0.93
	Bagging	0.93	0.93	0.07	0.94	0.93	0.93	0.87
	LogitBoost	0.93	0.93	0.07	0.94	0.93	0.93	0.87
	Random Forest	0.96	0.96	0.03	0.97	0.96	0.96	0.93
	MultiBoostAB	0.96	0.96	0.03	0.97	0.96	0.96	0.93
	Decorate	1.00	1.00	1.00	1.00	1.00	1.00	1.00
Gömülü	AdaBoost	0.84	0.84	0.13	0.84	0.84	0.84	0.68

	Bagging	0.84	0.84	0.13	0.84	0.84	0.84	0.68
	LogitBoost	0.84	0.84	0.13	0.84	0.84	0.84	0.68
	Random Forest	0.87	0.87	0.09	0.87	0.87	0.87	0.75
	MultiBoostAB	0.84	0.84	0.16	0.84	0.84	0.84	0.68
	Decorate	0.90	0.90	0.08	0.90	0.90	0.90	0.81
Sarmal	AdaBoost	0.87	0.87	0.12	0.87	0.87	0.87	0.75
	Bagging	0.87	0.87	0.12	0.87	0.87	0.87	0.75
	LogitBoost	0.87	0.87	0.12	0.87	0.87	0.87	0.75
	Random Forest	0.90	0.90	0.09	0.90	0.90	0.90	0.81
	MultiBoostAB	0.87	0.87	0.12	0.87	0.87	0.87	0.75
	Decorate	0.90	0.90	0.09	0.90	0.90	0.90	0.81

Çalışma sürelerinde ise sarmal yöntem 1 dakika 9 saniye sürerken, filtreleme yöntemi 32 saniye, gömülü yöntemler 2 saniye olarak kaydedilmiştir.

4 Tartışma ve Sonuç

Kullanılan kolorektal kanser histolojik doku görüntüsü veri setine ait çalışmaya bakıldığında, veri ön işleme aşamasının göz ardı edildiği görülmüştür [2]. Bu veri setinin kullanıldığı literatür taramasında, topluluk öğrenme algoritmalarını bir arada değerlendiren ve bu çalışmada olduğu gibi sınıf gürültüsü ve sınıf dengesizliği gibi problemlerin var olduğu durumlarda; hem orijinal hem de işlenmiş veri setleri için algoritmalarının performanslarının karşılaştırıldığı benzer bir çalışmaya da rastlanmamıştır. Veri ön işleme sonrası en başarılı algoritma %93 doğruluk oranıyla Logitboost iken; öznitelik seçiminde kullanılan CfsSubsetEval filtreleme yönteminde ise %100 doğruluk oranıyla Decorate algoritmasıdır. İlk aşamada en hızlı çalışan algoritma Random Forest iken, ikinci aşamada gömülü yöntem en iyi sonucu vermiştir. Sonuç olarak veri ön işleme ve öznitelik seçimi yöntemlerinin uygulanması sınıflandırma performansını arttırırken, zaman ve maliyet açısından da karar vermede etkinlik sağlamaktadır.

Kaynaklar

1. Bolón-Canedo, V., Sánchez-Maroño, N., & Alonso-Betanzos, A. Feature selection for high-dimensional data. Progress in Artificial Intelligence, (2016).
2. Kather, J. N., Weis, C. A., Bianconi, F., Melchers, S. M., Schad, L. R., Gaiser, T., Marx, A. & Zöllner, F. G. (2016). Multi-class texture analysis in colorectal cancer histology. Scientific Reports, 6, 27988.
3. Joshi, M. A. (2018). Digital image processing: An algorithmic approach. PHI Learning Pvt. Ltd.
4. Zhou, Z. H. (2012). Ensemble methods: foundations and algorithms. Chapman and Hall/CRC.
5. https://www.kaggle.com
6. Stańczyk, U., Zielosko, B., & Jain, L. C. (Eds.). (2018). Advances in Feature Selection for Data and Pattern Recognition. Springer International Publishing.

Sağlık Verilerinde Veri Ön İşleme Sonrası Topluluk Öğrenme Sınıflandırma Algoritmalarının Performans Değerlendirmesi

Yüksel Özkan[1], Mert Demirarslan[1], Aslı Suner[1]

[1] Biyoistatistik ve Tıbbi Bilişim Anabilim Dalı, Tıp Fakültesi, Ege Üniversitesi, İzmir, Türkiye

Performance Evaluation of Ensemble Learning Classification Algorithms After Data Preprocessing in Health Data

Abstract. While classifying for the identification and examination of disease in the health field, ensemble learning methods are used to educate multiple learners at the same time to establish more successful models. In this study, it is aimed to compare performance of classification algorithms after data preprocessing to problems such as missing data, class noise and class imbalance that may be encountered in disease diagnosis data sets. In the study, data collected from KEEL database were used to diagnose diseases such as heart disease, thyroid, hepatitis, lymphedema, breast cancer and diabetes. Random forest, weighted subspace random forest, additive logistic regression and gradient boosted machines algorithms were used in the classification. Accuracy, sensitivity, specificity, precision, Kappa statistic, Youden index, F - measure and ROC measurement metrics were used to compare performance of algorithms. At the same time, run times of algorithms were calculated. All statistical analyzes were performed with RStudio 1.2.1335 - Windows 7+ (64-bit) program. When performances of algorithms were compared for original data and processed data, it was seen that performance success of algorithms increased after data preprocessing. Overall, performance of the incremental algorithms yielded higher results than bagging algorithms. When algorithms are compared in terms of run time, boosting algorithms are the longest running algorithms. As a result, data preprocessing step should not be overlooked if high performance success is targeted. In absence of time constraints, use of gradient boosted machines algorithm provides more successful results in terms of performance.

Keywords: Data Preprocessing, Missing Values, Class Noise, Class Imbalance, Ensemble Learning.

Özet. Sağlık alanında hastalığın tanımlanması ve incelenmesi için sınıflandırma yaparken, topluluk öğrenme yöntemleriyle birden fazla öğreniciyi aynı anda eğiterek daha başarılı modellerin kurulması sağlanmaktadır. Bu çalışmada, has-

talık tanısı veri setlerinde olası karşılaşılabilecek kayıp gözlem, sınıf gürültüsü ve sınıf dengesizliği gibi problemlere veri ön işleme yapıldıktan sonra, sınıflandırma algoritmalarının performanslarının karşılaştırılması amaçlanmıştır. Çalışmada, KEEL veri tabanından kalp hastalığı, tiroit, hepatit, lenf ödem, meme kanseri ve diyabet gibi hastalıkların tanısı için toplanmış 8 farklı veri seti kullanılmıştır. Sınıflandırmada rastgele orman, ağırlıklı alt uzay rastgele orman, eklemeli lojistik regresyon ve gradyan artırma makinaları algoritmaları kullanılmıştır. Algoritmaların performanslarının karşılaştırılmasında doğruluk, duyarlılık, seçicilik, kesinlik, Kappa istatistiği, Youden indeksi, F - ölçütü ve ROC ölçüm metrikleri kullanılmıştır. Aynı zamanda, algoritmaların çalışma süreleri hesaplanmıştır. Tüm istatistiksel analizler, RStudio 1.2.1335 - Windows 7+ (64-bit) programı ile yapılmıştır. Orijinal veriler ve işlenmiş veriler için algoritmaların performansları karşılaştırıldığında, veri ön işlemeden sonra algoritmaların performans başarılarının arttığı görülmüştür. Genel olarak, artırma algoritmalarının performansları torbalama algoritmalarına göre daha yüksek sonuçlar vermiştir. Algoritmalar çalışma süreleri açısından kıyaslandığında ise, artırma algoritmaları en uzun süre çalışan algoritmalardır. Sonuç olarak, yüksek performans başarısı hedefleniyorsa, veri ön işleme aşaması göz ardı edilmemelidir. Zaman kısıtı olmadığı durumda, gradyan artırma makinaları algoritmasının kullanılması performans açısından daha başarılı sonuçlar elde edilmesini sağlamaktadır.

Anahtar Kelime: Veri Ön İşleme, Kayıp Gözlem, Sınıf Gürültüsü, Sınıf Dengesizliği, Topluluk Öğrenme.

1 Giriş

Sağlık alanında üretilen bilginin hızının artmasına paralel olarak, bu alandaki karar verme süreçlerine ilişkin karar desteği uygulamalarında da sayıca bir artış söz konusu olmaktadır [1]. Bunun sonucu olarak, makine öğrenmenin tıbbi tanıdaki uygulamaları, gelişmiş ve karmaşık veri analizini mümkün kılan algoritmaların, sistemlerin ve metodolojilerin ortaya çıktığına işaret etmektedir [2]. Makine öğrenmesi yöntemleri, biyomedikal alandaki verilere ait tanımlanmamış ilişkilerin ve gizli örüntülerin ortaya çıkarılmasında oldukça önemli bir potansiyele sahiptir. Aynı zamanda, makine öğrenmesi, sağlık uzmanlarının hassas tıp olarak bilinen kişiselleştirilmiş bakım hizmetine geçmelerini sağlayan büyük veri setlerini otomatik olarak anlamlı ve yorumlanabilir hale getirmelerine yardımcı olabilmektedir [3]. Jutel (2011), sınıflandırmanın tıpta pratiğe rehberlik ettiğini ve sınıflandırmayı anlamanın, tanı sonuçlarını daha iyi anlama arayışının bir parçası olması gerektiğini savunmuştur [4]. Makine öğrenme yöntemleri; tıbbi tanı koymada, hastaların klinik ve laboratuvar semptomlarına dayalı olarak, hastalıklarının uygun verilerle analiz edilebilmesi ve belli hastalıklar için daha verimli sonuç elde edilmesini sağlayan, zaman ve maliyet kaybını önleyen yöntemlerdir [5].

2 Yöntem

Çalışmada kullanılan *Cleveland, Heart, Hepatitis, Lymphography, Mammography, Newthyroid, Pima* ve *Thyroid* veri setleri KEEL adı verilen açık kaynaklı bir java yazılım aracından elde edilmiştir [6]. R paketleriyle fonksiyonları bilgisayara yüklendikten sonra, orijinal verilerin topluluk öğrenme yöntemleri kullanılarak analizi yapılmıştır. Daha sonra orijinal verilerde yer alan olası problemler için veri ön işleme aşaması tamamlanmış ve işlenmiş veriler kaydedildikten sonra analizler tekrarlanmıştır. Son olarak, hem orijinal verilerin hem de işlenmiş verilerin performansları karşılaştırılıp, algoritmaların çalışma süreleri de hesaplanarak en başarılı modele karar verilmiştir. Çalışmada, sağlık alanında en çok tercih edilen torbalama algoritmaları, rastgele orman (*random forest-rf*) ve ağırlıklı alt uzay rastgele orman (*weighted subspace random forests - wsrf*) iken; yaygın olarak kullanılan artırma algoritmaları, eklemeli lojistik regresyon (*additive logistic regression - logitboost*) ve gradyan artırma makinaları (*gradient boosting machines - gbm*) algoritmaları tercih edilmiştir. Kayıp gözlem problem için çoklu atama yöntemi, sınıf gürültüsü problem için melez yeniden etiketleme algoritması ve sınıfların dengelenmesi için SMOTE yöntemi kullanılmıştır. Topluluk öğrenme algoritmalarının performansları karşılaştırılırken; doğruluk duyarlılık, seçicilik, kesinlik, Kappa istatistiği, Youden indeksi, F - ölçütü ve ROC ölçüm metrikleri kullanılmıştır. Tüm istatistiksel analizler, RStudio 1.2.1335 - Windows 7+ (64-bit) programı ile yapılmıştır.

3 Bulgular

Kullanılan veri setleri için veri ön işleme yapıldıktan sonra sınıflandırma başarılarının arttığı gözlemlenmiştir. Buna bağlı olarak, hem orijinal hem de işlenmiş veri seti için setlerinin en başarılı algoritmaları Tablo 1'de verilmiştir.

Tablo 1. Orijinal ve işlenmiş veri setlerinin en başarılı algoritmaları.

Veri Seti	Orjinal	İşlenmiş
Cleveland	Gbm	Gbm
Heart	Random Forest	Gbm
Hepatitis	Gbm	Logitboost
Lymphography	Logitboost	Gbm
Mammography	Logitboost	Logitboost
Newthyroid	Random Forest	Logitboost
Pima	Gbm	Wsrf
Thyroid	Gbm	Logitboost

Bu sonuçlara göre, artırma algoritmaları torbalama algoritmalarına göre daha başarılı sonuçlar vermiştir. Veri setinin genişliği arttıkça algoritmaların çalışma süreleri de aynı şekilde artmaktadır. İşlenmiş veriler, orijinal verilere göre daha uzun süre çalışmaktadır. Gbm algoritması, en uzun çalışma süresine sahip algoritma iken; rf algoritması, en kısa çalışma süresine sahip algoritmadır. Thyroid verisi en geniş örneklem

büyüklüğüne sahip olduğundan, hem orijinal veride hem de işlenmiş veride en uzun çalışma süresine (168,77 dakika) sahiptir. Diğer yandan, Newthyroid verisi hem orijinal veride hem de işlenmiş veride en kısa sürede (2,36 dakika) çalışan veri setidir. Veri ön işleme aşamasında, sınıf gürültüsü problemi için filtreleme işlemi en uzun süren aşamadır.

4 Tartışma ve Sonuç

Literatürde, sağlık alanında yapılan sınıflandırma çalışmalarına bakıldığında veri ön işlemenin önemi vurgulanırken, veri ön işleme aşamasının göz ardı edildiği çalışmalarda mevcuttur [7]. Fakat rf, wsrf, logitboost ve gbm algoritmalarını bir arada değerlendiren ve bu çalışmada olduğu gibi kayıp gözlem, sınıf gürültüsü ve sınıf dengesizliği gibi problemlerin var olduğu durumlarda hem orijinal hem de işlenmiş veri setleri için topluluk öğrenme algoritmalarının performanslarının karşılaştırıldığı benzer bir çalışmaya literatürde rastlanmamıştır. Sonuç olarak, özellikle büyük veride makine öğrenme algoritmaları kullanılacaksa, veri ön işlemenin göz ardı edilmemesi gerekmektedir. Böylelikle, gözle görülür bir şekilde verilerin sınıflandırma başarılarında artış olması beklenmektedir.

Kaynaklar

1. Osamor, P.E., Grady, C.: Women's autonomy in health care decision-making in developing countries: a synthesis of the literature. Int. J. Womens. Health. 8, 191–202 (2016).
2. Kononenko, I.: Machine learning for medical diagnosis: History, state of the art and perspective. Artif. Intell. Med. 23, 89–109 (2001).
3. Azencott, C.: Machine learning and genomics : precision medicine vs . patient privacy. 1–14 (2018).
4. Jutel, A.: Classification, Disease, and Diagnosis. Perspect. Biol. Med. 54, 189–205 (2011).
5. Raval, D., Bhatt, D., Kumhar, M.K., Parikh, V., Vyas, D.: Medical Diagnosis System Using Machine Learning. Int. J. Comput. Sci. Commun. 7, 177–182 (2015).
6. Alcalá-Fdez, J., Sánchez, L, García, S, Del Jesus, M J, Ventura, S, Garrell, J M, Otero, J, Romero, C, Bacardit, J, Rivas, V.M., Fernández, J C, Herrera, F, García, S., Herrera, F., Sánchez, L., Otero, J., Del Jesus, M.J.: KEEL: a software tool to assess evolutionary algorithms for data mining problems. Soft Comput. 13, 307–318 (2009).
7. Zhang, Z., Zhao, Y., Canes, A., Steinberg, D., Lyashevska, O.: Predictive analytics with gradient boosting in clinical medicine. Ann. Transl. Med. 7, 152–159 (2019).

Erken Çocukluk Döneminde Otizm Spektrum Bozukluğu Teşhisine Yönelik Bir Tahmin Model Önerisi

Neslihan Baki[1] , Erman Esnafoğlu[2] , Kemal Turhan[3] , Cansu Gündoğan[4]

[1] Karadeniz Teknik Üniversitesi, Trabzon, Türkiye
[2]Ordu Üniversitesi, Ordu, Türkiye
[3] Karadeniz Teknik Üniversitesi, Trabzon, Türkiye
[4] Akdeniz Üniversitesi, Antalya, Türkiye

Özet

Giriş-Amaç: Otizm spectrum bozukluğu (OSB), yaşamın erken dönemlerinde başlayan ve yaşam boyu süren nöropsikiyatrik bir bozukluktur. OSB'nin kesin tanısına yönelik bu güne kadar nesnel bir yöntem ve biyolojik bir bulgu bulunamadığı belirtilmiştir. Otizm erken tanısı ile erken müdahalenin önemli tıbbi, sosyal, akademik ve ekonomik katkıları olduğu bildirilmiştir. Çalışmada veri kısıtı mevcut olup, literature önemli katkı sağlayacağı düşünülerek öncü bir çalışma olarak değerlendirilebilir. Bu çalışmanın amacı, otizmde değişiklik gösteren bazı kan paremetreleri kullanılarak, erken çocukluk döneminde teşhise yardımcı olabilecek nesnel tabanlı bir tahmin modeli geliştirmektir.

Yöntem: Bu amaç doğrultusunda geriye dönük 23 OSB'li ve 24 OSB'li olmayan çocuk hasta verileri yaş, cinsiyet, BMI, B vitamini, folat, D vitamini, zonulin vb. açışından değerlendirildi. R programlama ile makine öğrenmesi yöntemlerinden Destek Vektör Makinesi (DVM) sınıflandırma algoritması ile dört farklı çekirdek (linear, radial, polynomial, sigmoid) fonksiyonu kullanılarak model geliştirilmiştir.

Bulgular: DVM linear çekirdek fonksiyonu ile duyarlılık % 75, özgüllük % 87 ve AUC % 81, radial ile duyarlılık % 100, özgüllük % 90 ve AUC % 92, polynomial ile duyarlılık % 100, özgüllük % 64 ve AUC % 60, sigmoid ile duyarlılık % 80, özgüllük % 72 ve AUC % 73 olarak elde edilmiştir.

Sonuç: Radial çekirdek fonksiyonu ile geliştirilen model duyarlılık % 100, özgüllük % 90 ve AUC % 92 ile en başarılı tahmin modeli olarak öne çıkmıştır. Böylece OSB'nin erken dönemde tespitine yönelik nesnel tabanlı başarılı bir tahmin modeli geliştirilmiştir.

Anahtar Kelimeler: destek vektör makinesi, otizm spektrum bozukluğu, klinik karar destek sistemleri

A Prediction Model Proposal For The Diagnosis Of Autism Spectrum Disorder In Early Childhood clinical

Neslihan Baki[1] , Erman Esnafoğlu[2] , Kemal Turhan[3] , Cansu Gündoğan[4]

[1] Karadeniz Teknik Üniversitesi, Trabzon, Türkiye
[2]Ordu Üniversitesi, Ordu, Türkiye
[3] Karadeniz Teknik Üniversitesi, Trabzon, Türkiye
[4] Akdeniz Üniversitesi, Antalya, Türkiye

Abstract

Introduction-Objective: Autism spectrum disorder is a life-long neuropsychiatric disorder that begins early in life. To date, it has been reported that there is no objective method and biological finding for the definitive diagnosis of ASD. Early intervention with early diagnosis of autism has been reported to have significant, medical, social, academic and economic contributions. There is data limitation in the study and it can be considered as a pioneering study which is thought to make a significant contribution to the literature. The aim of this study is to develop an objective medical-based prediction model that can help diagnose early childhood by using some blood parameters that vary in autism.

Method: For this purpose, 23 children with ASD and 24 children without ASD were evaluated for age, gender, BMI, vitamin B, folate, vitamin D, zonulin. The model has been developed by using four different kernel (linear, radial, polynomial, sigmoid) functions with support vector machine (SVM) classification algorithm which is one of the machine learning methods with R programming.

Findings: With support vector machine linear core function; sensitivity 75%, specificity 87%, AUC 81%, with radial; sensitivity 100%, specificity 90%, AUC 92%, with polynomial; sensitivity 100%, specificity 64%, AUC 60%, with sigmoid; sensitivity 80%, specificity 72%, AUC 73%.

Results: The model developed with radial core function, sensitivity 100%, specificity 90%, AUC 92% has emerged as the most successful prediction model. Thus, an objective medical-based prediction model for early detection of ASD has been developed.

Keywords: Support vector machine, autism spectrum disorder, clinical decision support system.

References

1. American Psychiatric Association, Diagnostic and Statistical Manual of Mental Disorders (DSM IV), Washington, DC: American Psychiatric Association Press, 1994.
2. Kulaksızoğlu A: Farklı Gelişen Çocuklar, Epsilon Yayıncılık, İstanbul, 2003.
3. Prater C. D, Zylstra R.G: Autism: A medical primer‖, American Family Physician, 66(9), 1667-1674, 2002.
4. Kara B: İstanbul'da yaygın gelişimsel bozuklukların tanısında m-chat testinin geçerliliği, Uzmanlık Tezi, İstanbul Üniversitesi, Tıp Fakültesi, 2009.
5. Akşehirli, Ö. Y., Ankarali, H., Aydin, D., & Saraçli, Ö: Tıbbi Tahminde Alternatif Bir Yaklaşım: Destek Vektör Makineleri. *Turkiye Klinikleri Journal of Biostatistics*, *5*(1), (2013).
6. Alpaydin, E: *Introduction to machine learning*. MIT press, (2009).

Comparative Analysis of Manual Delineation, Semi-automatic Extraction and Automatic Deep Models for Segmentation in Liver, Spleen and Kidney Volumetry from MRI

Naciye Sinem Gezer[1], Mustafa Mahmut Barış[1], Ali Emre Kavur[2], Ulaş Yüksel[2], Oğuz Dicle[1], Mustafa Alper Selver[2]

1Dokuz Eylül University, Faculty of Medicine, Department of Radiology

2Dokuz Eylül University, Department of Electrical and Electronics Engineering

Introduction

The recent studies show that the segmentation of emerging deep models outperforms semi-automatic techniques for liver volumetry in CT [1]. However, for MRI, existing analysis remain dated and does not include recently proposed deep models [2]. Thus, there is still no comparison analyzing how well these emerging automatic models perform liver volumetry in MR images, which have their own modality specific challenges as illustrated in Fig. 1.

This study is performed to compare the accuracy and repeatability of manual, semi-automatic and recently proposed automatic (i.e., deep learning based) segmentation methods for determining liver, spleen and kidney volumes in healthy patients at magnetic resonance (MR) imaging.

Materials and Methods

The database contains 20 MR DICOM series, each of which includes two T1-weighted datasets (i.e., T1-DUAL sequence: in-phase and out-phase) and a T2 weighted (i.e., T2-SPIR Spectral Pre-Saturation Inversion Recovery sequence). The data sets are acquired by a 1.5T Philips MRI, which produces 12-bit DICOM images having a resolution of 256 x 256. The Inter Slice Distances (ISDs) vary between 5.5-9 mm (average 7.84 mm), x-y spacing is between 1.36 - 1.89 mm (average 1.61 mm) and the number of slices is between 26 and 50 (average 36).

For 20 healthy patients (12 men and 8 women; mean age, 39 years; age range, 23– 54 years), an experienced radiologist and an imaging scientist have performed manual segmentations together using 3D slicer program. The results are also used as the ground truth of the study. Another imaging scientist has applied the semi-automatic segmentation method, which is developed specifically for this study, to the same datasets. The semiautomatic segmentation algorithm is implemented on 3Dslicer program and based on three steps: (a) manual adjustment of a threshold value for preprocessing (b) placing initialization seed(s) all over the volume of interest using multi-planar images and running the algorithm, (c) observing the result and possibly modifying it by cropping tools or re-running the segmentation algorithm with updated parameters.

Three models (DeepMedic [3], U-Net [4], and NiftyNet [5]) are tested in the automatic category, all of which are based on emerging deep learning based strategy. The performances of these frameworks shows the current trend in radiological image analysis by achieving the state-of-the-art results for various applications. Besides their outstanding performance, setting the parameters of these models or making even slight revisions in the architecture to obtain higher performance is still far away from being trivial [6]. The above mentioned deep models are trained with another set of MR series, which also include 20 patients and their manually extracted ground truth.

The results are evaluated by taking the average of five metric(s): Volumetric overlap (VO), Relative volume difference (RVD), Average symmetric surface distance (ASSD), Root mean square symmetric surface distance (RMSD), Maximum symmetric surface distance (MSSD) [7]. Each measurement was timed and the time needed for manual, semi-automatic segmentation and automatic were also compared.

Results

The inter-expert analysis reveal that the performance of manual extraction can achieve 93% performance. Based on this baseline, the semi-automatic segmentation results get percentage of 83.9% ± 4.1 for VO, 83.6% ± 11.8 for RVD, 92.6% ± 1.6 for ASSD, 92.9% ± 1.5 for RMSD and 86.4% ± 4.8 for MSSD. In average, semiautomatic method achieve 87.9% ± 3.9. Among the deep models, the highest performance was achieved by the deep medic, which is equal to 85.4% ± 20.7 for VO, 72.9% ± 32.4 for RVD, 88.7% ± 7.1 for ASSD, 85.8% ± 8.3 for RMSD and 53.0% ± 28.8 for MSSD. In average, semiautomatic method achieve 77.2% ± 16.0.

Mean interaction time was reduced from 25 minutes with manual segmentation to 15 minutes with semi-automatic segmentation and less than 3 minutes with automatic segmentation. The mean total time for the semiautomatic process was 14 minutes 20 seconds while it is 2 minutes 50 seconds with deep models.

Conclusion

Although the deep models have achieved better average VO performance compared to semi-automatic method, they fall behind when all metrics are considered. The semi-automatic method has higher repeatability as oberseved from significantly less standard deviation of the results. The biggest difference between The emerging automatic models and deep learning strategies have not reached the performance of semi-automatic techniques for liver volumetry from MRI images. On the other hand, the of the automatic segmentation models substantially reduces the time needed for volumetric measurement of the liver.

References

[1] Hermoye L, Laamari-Azjal I, Cao Z, et al. Liver segmentation in living liver transplant donors: comparison of semiautomatic and manual methods. Radiology 2005 Jan;234(1):171-178.

[2] Kamnitsas K, Ledig C, Newcombe VF, et al. Efficient multiscale 3D CNN with fully connected CRF for accurate brain lesion segmentation. Medical Image Analysis 2017;36:61-78.

[3] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation. In International Conference on Medical Image Computing and Computer-Assisted Intervention 2015;234-241.

[4] Gibson E, Li W, Sudre C, et al. NiftyNet: A deep-learning platform for medical imaging. Computer Comput Methods Programs Biomed 2018;158:113-122.

[6] de Vos BD, Wolterink JM, de Jong PA, Viergever MA, Išgum I. 2D image classification for 3D anatomy localization: employing deep convolutional neural networks. Proceedings of the SPIE on Medical Imaging 2016; 97841Y.

[7] Yeghiazaryan, Varduhi, and Irina Voiculescu. "An overview of current evaluation methods used in medical image segmentation." Dept. Comput. Sci., Univ. Oxford, Oxford, UK, Tech. Rep. CS-RR-15-08 2015.

Figures

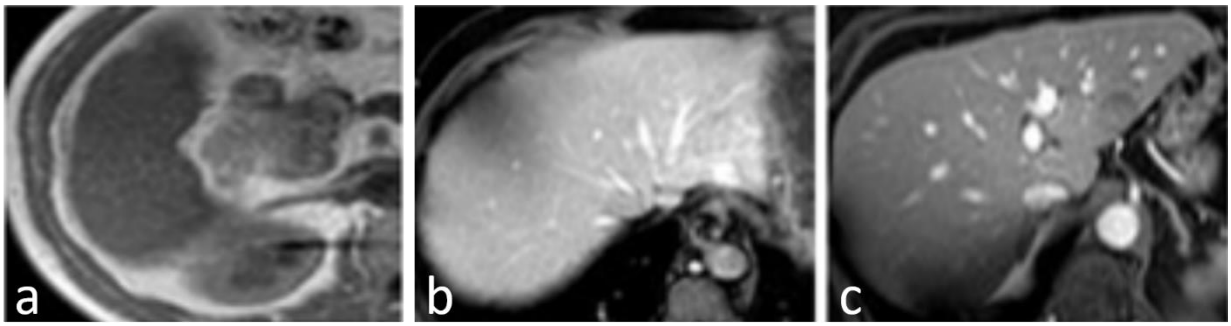

Figure 1. Examples of segmentation challenges (a) sudden changes in axial view and unclear boundary (liver-right kidney). Effect of bias field on liver (b) T1-DUAL, and (c) T2-SPIR.

Mezenkimal epitelyal dönüşüm (MET) sürecini düzenleyen transkripsiyon faktörlerinin epigenetik yeniden programlama süreci üzerindeki etkilerinin saptanması

Burcu Sengez[1,2 [0000-0002-1833-4135]], Nazmiye Arslan[1], Gökhan Karakülah[1,2 [0000-0001-6706-1375]], Hani Alotaibi[1,2 [0000-0001-7423-9653]]

1. Izmir Biomedicine and Genome Center, 35340 Izmir, Turkey
2. Izmir International Biomedicine and Genome Institute, Dokuz Eylül University, 35340 Izmir, Turkey

burcu.sengez@ibg.edu.tr, nazmiye.arslan@ibg.edu.tr, gokhan.karakulah@ibg.edu.tr, hani.alotaibi@ibg.edu.tr

Özet

Epitelyal mezenkimal dönüşüm (EMT) ve mezenkimal epitelyal dönüşüm (MET) süreçleri düzgün bir embriyonik gelişim sürecinin yanı sıra, tümorogenez ve metastaz süreçleri bakımından da kritik öneme sahip biyolojik olaylardır. Klasik tanımlar halen MET sürecini, EMT sürecinin tersi olarak tanımlasa da, MET çok daha karmaşık ve dinamik bir süreçtir.

Çalışmalarımız MET sürecini kontrol eden transkripsiyon faktörlerinin varlığını ve bu faktörlerin bazılarının kromatin altyapısının üzerinde de büyük etkisi olduğunu göstermektedir. Bu amaçla, MET sürecinde kromatin altyapısını ve epigenetik yeniden programlamayı etkileyen transkripsiyon faktörlerinin tanımlanması amaçlanmıştır. MET sürecini belirleyen kromatin yeniden düzenleyici moleküllerin ve epigenetik altyapının belirlenmesi için ileri düzey deney sistemi ve analiz yöntemleri bir arada uygulanmıştır. Transkripsiyon faktörlerinin hedefleri ve kromatin altyapısında meydana gelen değişimler RNA-Seq ve ChIP-Seq yöntemleriyle kapsamlı olarak analiz edilmiştir. Ön verilerimiz MET sürecindeki gen ifade değişikliklerinin sürecin ilk saatlerinde başladığını ve ortaya çıkan öncül genlerin tüm dinamizmi kontrol ettiğini işaret etmektedir. Aday transkripsiyon faktörü olarak seçilen *Grhl3*, *Elf3* ve *Cebpa* faktörlerine ait hedef genler incelendiğinde birçok ortak genin (*Ahr* gibi) ve kromatin düzenleyici faktörün olduğu saptanmıştır. Ortak genlerin birçoğunun tümorogenez,, mitoz, kromatin altyapısının düzenlenmesi gibi biyolojik süreçler açısından büyük önem arz ettiği görülmüştür.

MET sürecini düzenleyen faktörler ve epigenetik alt yapı arasındaki ilişkinin aydınlatılmasının ileri vadede MET sürecinin rol aldığı kanser metastazı ve gelişim bozukluklarına karşı geliştirilecek tedavilerde kullanılacak yeni hedeflerin bulunmasını sağlaması hedeflenmektedir.

Anahtar Kelimeler: Mezenkimal Epitelyal Dönüşüm, Epigenetik Yeniden Programlama, *Elf3, Grhl3*

Abstract

Identification of transcription factors influencing the epigenetic reprogramming during the mesenchymal to epithelial transition (MET)

The epithelial to mesenchymal transition (EMT) and the mesenchymal to epithelial transition (MET) are crucial for proper embryonic development but are also exploited by tumor cells. We and others have demonstrated that MET is not simply the reverse process of EMT, it is a complicated and dynamic process.

We have identified transcription factors with a direct impact on the initiation and maintenance of MET. Such transcription factors have a strong influence on the chromatin infrastructure, and of course transcriptional regulation cannot exist with the proper chromatin infrastructure. Therefore, we aim to identify the transcription factors influencing the epigenetic reprogramming and chromatin infrastructure during MET. For this reason, we generated a comprehensive genome-wide map of the chromatin infrastructure representing the mesenchymal to epithelial transition using high-throughput methods. In addition, we identified and map genetic and epigenetic targets of these transcription factors utilizing ChIP-Seq and RNA-Seq technologies. Our preliminary data indicate that gene expression changes in the MET process began in the early hours of the process, and that the resulting early genes control all dynamism. When the target genes of *Grhl3, Elf3* and *Cebpa* factors selected as candidate transcription factors were examined, it was found that there were many common genes (such as *Ahr*) and chromatin regulatory factors. Many of the common genes have been shown to be of great importance for biological processes such as tumorogenesis, mitosis and the regulation of chromatin infrastructure.

We believe that in the long term, our findings about MET will provide new targets for the development of novel therapeutics dedicated to the management and treatment of developmental disorders and metastasized cancer.

Key words: Mesenchymal to Epithelial Transition, Epigenetic Reprogramming, Elf3, Grhl3

Amaç

Araştırmada mezenkimal epitelyal dönüşüm sürecinde kromatin altyapısını ve epigenetik yeniden programlamayı etkileyen transkripsiyon faktörlerinin tanımlanması amaçlanmıştır.

Konu-Kapsam

Hücresel fenotipin sürdürülmesi ve plastisitenin sağlanması çok hücreli canlılar için büyük önem arz etmektedir. EMT ve MET süreçleri de bu dinamik sürecin önemli bir kısmını oluşturmaktadır (Somarelli, J. A., et al. 2016). EMT sürecinde, epitelyal hücreler bağlantılarını ve apikal bazal polaritelerini kaybeder, hücre iskeletlerini tekrar organize ederler. Hücre şeklini belirleyen sinyal programlarında ve gen ifade profillerinde önemli değişimler meydana gelir.

EMT gelişim, yara iyileşmesi (wound healing), fibrozis ve kanser gelişimi açısından kritik öneme sahiptir (Lamouille, S., et al. 2014). MET ise motil hücrelerden sıkıca birbirine tutunan ve belirgin apikal bazal polaritesi bulunan hücrelerin oluşumunu tarif eden süreci tanımlamaktadır. MET hem gelişimsel, hem rejeneratif hem de patolojik bir çok oluşum için temel hücresel bir süreçtir (Antonello, Z. A., et al. 2015, Kim, H. Y., et al. 2016). Klasik tanımlar MET'i basitçe EMT sürecinin tersi olarak tanımlasa da, son yıllarda yapılan çalışmalar bunun öyle olmadığını açıkça vurgulamaktadır. MET sadece vimentin, N-cadherin gibi mezenkimal belirteçlerin azalarak ve E-cadherin gibi epitelyal belirteçlerin de artarak düzenlenmesinden çok daha karmaşık ve dinamik bir süreci tarif etmektedir. Bu dinamik ve kompleks sürecin sadece EMT ve MET belirteçlerinin artması veya azalmasıyla anlatılması ve düzenlenmesi mümkün değildir (Kim, H. Y., et al. 2016).

Ön verilerimiz MET'i kontrol eden farklı düzenleyicilerin varlığını kanıtlar niteliktedir (Sengez B et al. 2019, Alotaibi H. et al. 2015). EMT ve MET süreçleri transkripsiyonel, post-transkripsiyonel, translasyonel ve post-translasyonel birçok basamakta farklı düzenleyiciler tarafından kontrol edilmektedir (Lamouille, S., et al. 2013). Bu ifade seviyesindeki düzenlenmenin yanı sıra epigenetik modifikasyonlar da hücrenin fenotipik plastisite açısından dengede kalmasını sağlamaktadır (Somarelli, J. A., et al. 2016). Bu sıkı düzenlenmeden transkripsiyon faktörleri, kromatin tekrar düzenleyici faktörleri (chromatin reorganisation factors), yüzey reseptörleri ve adhezyon molekülleri gibi birçok faktörün sorumlu olduğu bilinmektedir (Bozzi, F., et al. 2016). Epigenomun dinamizmi transkripsiyon faktörlerinin kromatin ve kromatin düzenleyici enzimlerle ilişkisiyle sağlanmaktadır. Transkripsiyon faktörleri aktive edilerek kromatin altyapısı değişmekte ve bu faktörler DNA düzenleyici bölgelere bağlanmaktadır. Tüm bu süreçte kromatinde değişiklik yapabilen enzimler (chromatin modifying and remodeling enzymes) aktif rol oynamaktadır (Brettingham-Moore, K. H., et al. 2015).

Epigenetik modifikasyonlar DNA sekansından bağımsız olarak gen aktivitesi ve ekspresyonunu düzenleyebildiği ve tersinebilir olduğu için birçok biyolojik süreçte büyük önem arz etmektedir (McDonald, O. G., et al. 2011, Serrano-Gomez, S. J., et al. 2016). Ayrıca tüm DNA kalıbına ihtiyaç duyan süreçler (transkripsiyon, replikasyon, rekombinasyon gibi) kromatin altyapısının kompleks yapısından etkilenmektedir (Stadler, S. C. and C. D. Allis 2012).

Kök hücre differensiyasyonu ve germ hücre gelişimi gibi EMT sırasındaki epigenetik yeniden programlama da kromatin modifikasyonlarındaki değişimlerle sağlanmaktadır (McDonald, O. G., et al. 2011). Son yıllardaki çalışmalar, mezenkimal fenotipin genom üzerindeki lokus spesifik epigenetik yeniden programlamayla inşa edildiğini göstermektedir. Bir hipoteze göre, fenotipik geçiş transkripsiyon faktör aktivitesinin kromatin aracılıklı stabilizasyonuna bağlıdır. Kısaca, epitelyal ve mezenkimal hücre fenotipi kromatin durumundaki değişimlerle koordine edilmektedir (Cieslik, M., et al. 2013).

EMT sırasında görev alan bazı transkripsiyon faktörleri ve histon modifikasyonları arasındaki karşılıklı etkileşim uzun yıllardır çalışılmasına rağmen epigenetik yeniden programlanmanın doğası henüz tümüyle aydınlatılabilmiş değildir. MET açısından bakıldığında böyle yayınlar yok denecek kadar azdır. Olan birkaç yayında ise bazı kanser hücrelerinin MET açısından olası epigenetik hedeflerinin araştırılması hedeflenmiştir (Gregoire, J. M., et al. 2016). Bu genom çapında süre gelen epigenetik programlanmanın EMT/MET sürecindeki tam fonksiyonu ve mekanizmasına değinen çok az literatür bilgisi bulunmaktadır.

Tüm bu veriler, EMT/MET transkripsiyonel faktörlerinin kromatinde değişim yapabilen enzimler aracılığıyla düzenlenmesinin hem gelişim hem de kanser gibi patolojik koşullardaki önemini ve bu konudaki bilgi açığını vurgulamaktadır (Cieslik, M., et al. 2013, Ta Tam, W. L. and R. A. Weinberg 2013, Lee, J. Y. and G. Kong 2016, Sun, L. and J. Fang 2016). Bu faktörlerin transkripsiyon faktörleriyle olan ilişkisinin anlaşılması ve biyolojik önemlerinin kavranmasının gelişim ve kanser süreçlerindeki bu dinamik EMT/MET değişimlerinin anlaşılmasında önemli rol oynayacağı yadsınamaz bir gerçektir.

NMuMG (normal fare meme bezi) hücre hattı EMT-MET süreçlerinin çalışıldığı modellerden biridir. Bu hücreler TGFβ ile muamele edildiğinde E-cadherin ekspresyonlarını kaybetmeye başlar, kortikal aktin yerini stres fiberleri alır ve N-cadherin ile vimentin ekspresyonlarında artış gözlemlenir. TGFβ ortamdan uzaklaştığında, hücreler MET sürecine girer ve epitelyal

durumlarını yeniden kazanırlar. Genetik yapıdaki bu dramatik değişim, NMuMG hücre morfolojisini de büyük ölçüde etkileyerek bu hücreleri EMT-MET çalışmaları için ideal bir model yapmaktadır (Şekil1).

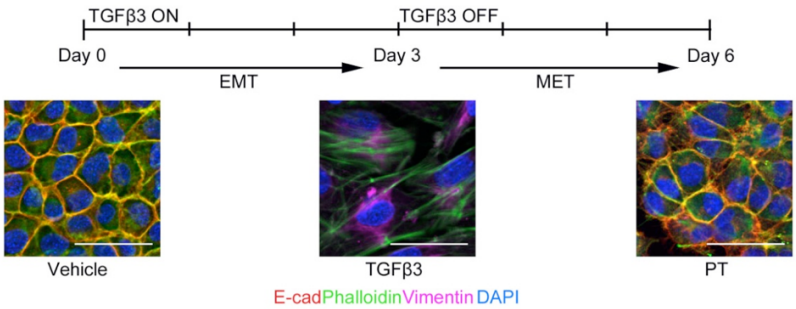

Şekil 1. EMT-MET hücresel modeli olan NMuMG hücrelerinin TGFβ3 muamelesi ve ardından morfolojilerinde oluşan değişimler (PT: muamele sonrası)

NMuMG hücreleri kullanılarak elde ettiğimiz sonuçlarda, MET sırasındaki Cdh1 aktivitesinin intron 2'de bulunan iki enhancer tarafından kontrol edildiği ve bu aktivasyonun Grhl3 ve Hnf4α transkripsiyon faktörlerinin bağlanmasıyla sağlandığı gösterilmiştir (Alotaibi H. et al. 2015).

Ön çalışmalarımız kapsamında, epitelyal ve mezenkimal ifade profillerini karşılaştırmasının ardından E-cadherin ile korelasyon gösteren epitelyal spesifik bir gen seti oluşturulmuştur. Bu liste içerisinden MET süreci açısından kritik olabilecek bazı faktörler (Elf3, Cebpα gibi) incelenmiş ve olası transkripsiyonel ilişkiler doğrulanmaya başlanmıştır. Ancak bu listede transkripsiyon faktörleri dışında kromatin düzenleyici enzimlerin (Carm1, Ezh2, Jarid2 gibi) varlığı da dikkat çekmektedir. Elde ettiğimiz sonuçlar ve literatür bilgileri ışığında, bir transkripsiyon faktörünün bir kromatin düzenleyici enzimle ilişkisini saptamanın ve bu etkileşimin başka transkripsiyon faktör/faktörlerini nasıl etkilediğini belirlemenin, MET'in transkripsiyonel düzenlemesini daha iyi anlayabilmemiz açısından önemli olduğunu düşünmekteyiz.

Tüm aday transkripsiyon faktörleri (*Grhl3*, *Elf3* ve *Cebpa*) ve kromatin düzenleyici faktörlerin arasındaki mekanistik ilişki göz önünde bulundurulduğunda, histon modifikasyonlarının genom bazındaki düzeni kullanılarak promotör, enhancer, insulator ve belirli bir hücre tipinde belirli bir fizyolojik koşulda ortaya çıkan heterokromatin bölgelerinin farklı tiplerini sınıflandırmak mümkün gözükmektedir (Fleming, J. D., et al. 2013). Ayrıca promotör bölgelerindeki histon kodlarının sekans spesifik transkripsiyon faktörlerinin daha önce oraya bağlanıp bağlanmamasıyla belirlendiğini düşünmek de mümkündür (Nardini, M., et al. 2013). Bu nedenle ana hedefimiz, MET sürecinde kromatin altyapısını ve epigenetik yeniden programlamayı etkileyen transkripsiyon faktörlerini tanımlamaktır.

Yöntem

MET sürecini kontrol edebilen kromatin yeniden düzenleyeci moleküllerin ve MET sırasındaki epigenetik altyapının belirlenmesi icin ileri düzey deney sistemi ve analiz yöntemleri birarada uygulanmıştır. Araştırma kapsamında veri madenciliği, yüksek verimli ekspresyon profili oluşturma, gen susturma, protein-protein ve DNA-protein etkileşim teknikleri ile doğrulama da dahil olmak üzere entegre bir yaklaşım kullanılmıştır. Transkripsiyon faktörlerinin hedefleri ve kromatin altyapısında meydana gelen değişimler RNA-Seq ve ChIP-Seq yöntemleriyle kapsamlı olarak analiz edilmiştir.

Bulgular

1. Ön verilerimiz MET sürecindeki gen ifade değişikliklerinin sürecin ilk saatlerinde başladığını ve ortaya çıkan öncül genlerin MET sürecinin dinamik altyapısını kontrol ettiğine işaret etmektedir. Bu nedenle, ChIP-Seq yöntemi kullanılarak MET sürecinin ilk 24 saati belirli saat aralıklarında analiz edilmiştir. İlk aşamada çalışılan histon belirteçleri H3K4me3, H3K27me3 ve H3K9Ac histon belirteçleridir.
2. Ardından aday epitelyal spesifik transkripsiyon faktörleri belirlenerek sessizleştirilmiş ve histon modifikasyonlarındaki değişiklikler belirlenmiştir.
3. Transkripsiyon faktörleri tarafından yönetilen epigenetik yeniden düzenlenmenin kapsamını anlamak için, transkripsiyon hedefleri ve hücrenin kromatin altyapısında meydana gelen değişimler RNA-Seq yöntemiyle analiz edilmiştir.

Sonuçlar

Çalışılan histon belirteçlerinin genom üzerinde kapladığı bölgelerdeki anotasyon dağılımlarındaki değişim kontrol edilmiştir (Şekil 2-4). H3K4me3 histon belirtecinde en büyük değişim promotör-TSS anotasyonunda olmuştur. Özellikle MET'nin 12. saatinde yüzdenin arttığı ve 24. saatinde mezenkimal durumdaki hücrelere kıyasla iki katına çıktığı gözlenmektedir. 5'UTR anotasyon oranında da 12. saatten itibaren ılımlı bir artış saptanmıştır. İntergenik ve intron anotasyon oranlarında büyük bir değişim gözlenmezken non-coding yüzdesinde 24. saatte bir artış gözlenmektedir (Şekil 2).

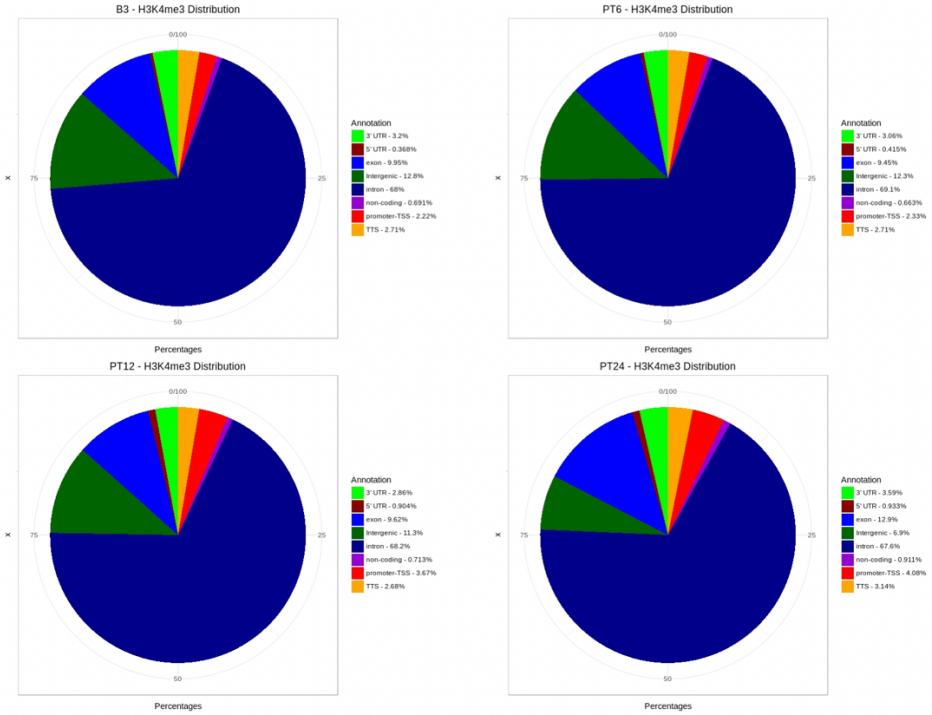

Şekil 2. Histone H3K4me3 tüm genom üzerinde kapladığı bölgelerin MET'nin farklı saatlerindeki anotasyon dağılımları. En çok değişim gözlenen promotör TSS grubu kırmızı renkle ifade edilmektedir.

H3K27me3 histon belirtecinin dağılımı incelendiğinde, en anlamlı değişim promotör-TSS dağılımında gözlenmekte ve MET ilerledikçe oranın düştüğü görülmektedir. Diğer oranlarda anlamlı bir değişim gözlenmezken 5'UTR oranında 24. saatte bir azalma bulunmaktadır (Şekil 3).

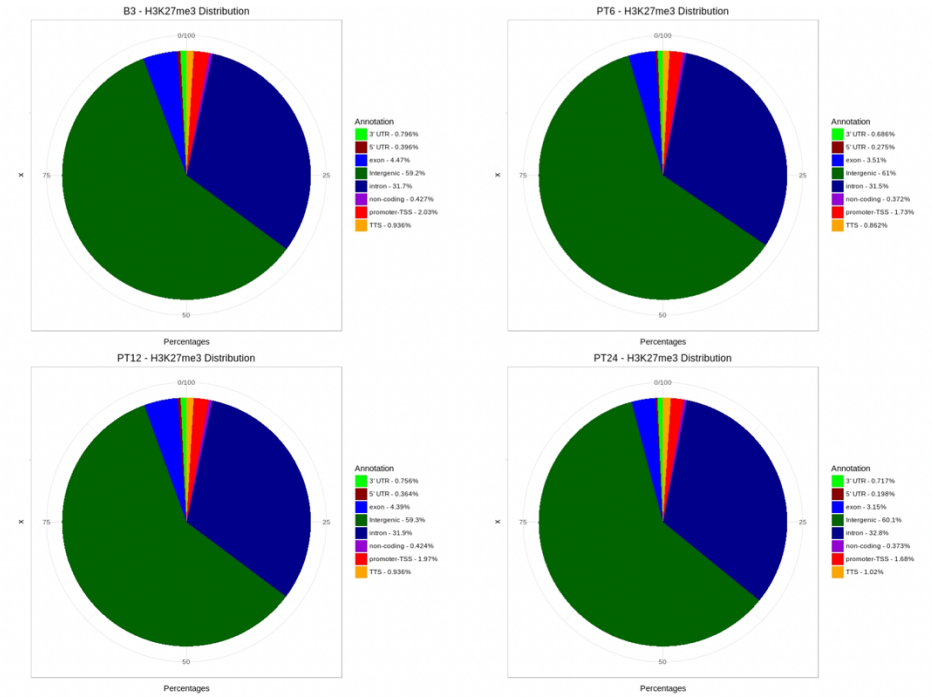

Şekil 3. Histone H3K27me3 tüm genom üzerinde kapladığı bölgelerin MET'nin farklı saatlerindeki anotasyon dağılımları. En çok değişim gözlenen promotör TSS grubu kırmızı renkle ifade edilmektedir.

Benzer şekilde, H3K9Ac histon belirtecindeki en anlamlı değişim de promotör-TSS oranında olmuştur. MET ilerledikçe oranda artış gözlenmekte ve özellikle 24. saatte oranın mezenkimal durumdaki hücrelere oranla 2 kat olduğu görülmektedir. 5'UTR oranında da özellikle 24. saatte bir artış saptanmaktadır (Şekil 4).

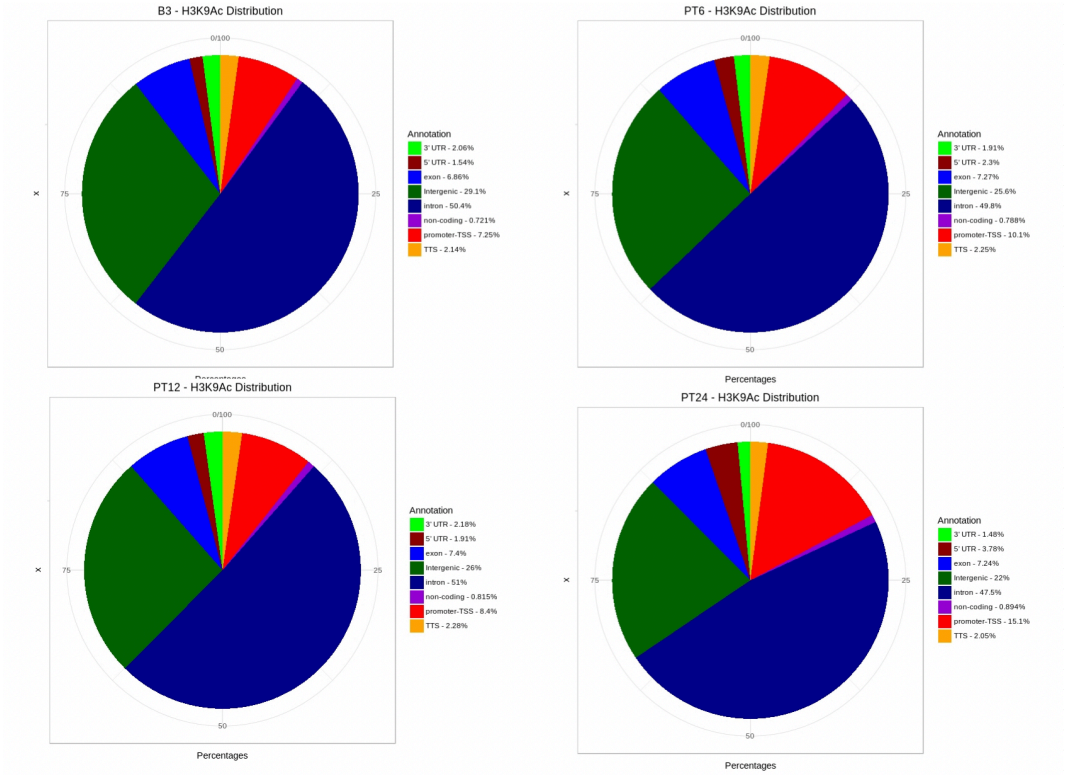

Şekil 4. Histone H3K9Ac tüm genom üzerinde kapladığı bölgelerin MET'nin farklı saatlerindeki anotasyon dağılımları. En çok değişim gözlenen promotör TSS grubu kırmızı renkle ifade edilmektedir.

Çalışılan tüm histon belirteçlerinin genom üzerinde kapladığı bölgelerin oranları saat bazında incelendiğinde, promotör-TSS oranının H3K4me3'teki anlamlı artışının PT12 saatinde başladığı ve 24. saatte en yüksek seviyeye ulaştığı; H3K27me3 ve H3K9Ac belirteçlerindeki değişimin ise PT24'te başladığı görülmektedir. İntergenik ve intronik bölgelere ait yüzdelerde büyük bir farklılık saptanmazken çoğu belirteçte 5'UTR ve non-coding anotasyon dağılımlarında 24. saatte bir değişim farkedilmektedir. Tüm veriler değerlendirildiğinde, MET sürecinin aktivasyonu için H3K4me3 ve H3K27me3 belirteçlerinin önemi gözlenmektedir. Yapılan analizler, MET sürecinin ilk saatlerindeki epigenetik değişimlerin bir kısmı için temel oluşturur niteliktedir.

Ardından, promotör bölgelerindeki histon modifikasyonlarının bağlanma değerleri farklı zaman aralıklarında incelenmiştir (Şekil 5). H3K4me3 belirtecinde saat bazında bir artış gözlenmekte ve bu artışın MET'nin 12. saatinde bir pik yaptığı görülmektedir. Beklenildiği üzere, H3K27me3 belirtecinin bağlanma değerlerinde MET ilerledikçe bir azalış saptanmıştır. Azalma 12. saatte başlamakta ve devam etmektedir. H3K9Ac belirtecinin bağlanma değerleri incelendiğinde, MET'nin ilk saatlerinde bir artış görülürken 24. saatte mezenkimal duruma oranla bir azalma görülmektedir.

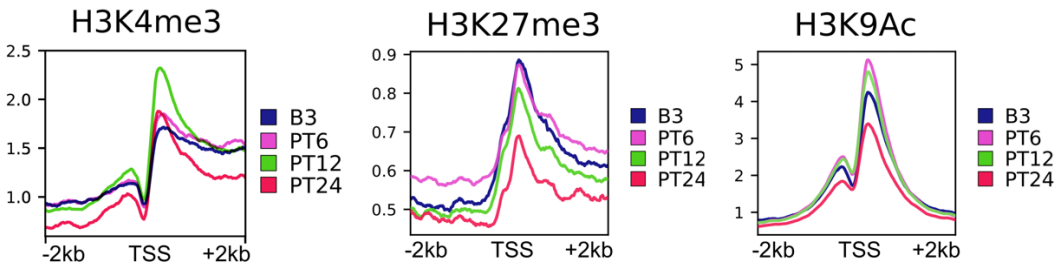

Şekil 5. Promotör bölgelerindeki histon modifikasyonlarının bağlanma değerlerinin farklı zaman noktalarındaki ortalama dağılımları. Gösterilen bölgeler UCSC veritabanından alınan mm10 fare genomundaki gen transkripsiyonu başlangıç noktalarının 2kb upstream ve downstream bölgeleridir. Y koordinatı, tranksripsiyon başlangıç noktasından eşit uzaklıkta

bulunan 10 nükleotid uzunluğundaki alt bölgelerin normalize kaplam (coverage) değerlerinin, bütün promotör bölgelerindeki ortalamalarını gösterir. Zaman noktaları renklerle temsil edilmiştir.

Tüm analizlerin ardından, ilgilendiğimiz genlerdeki histon belirteçlerindeki değişim IGV'de incelenmiştir. Cdh1 promotör bölgesinde H3K4me3 histon belirtecinde saat bazında anlamlı bir artış gözlenirken, H3K27me3'te tüm zaman aralıklarında azalma görülmektedir (Şekil 6).

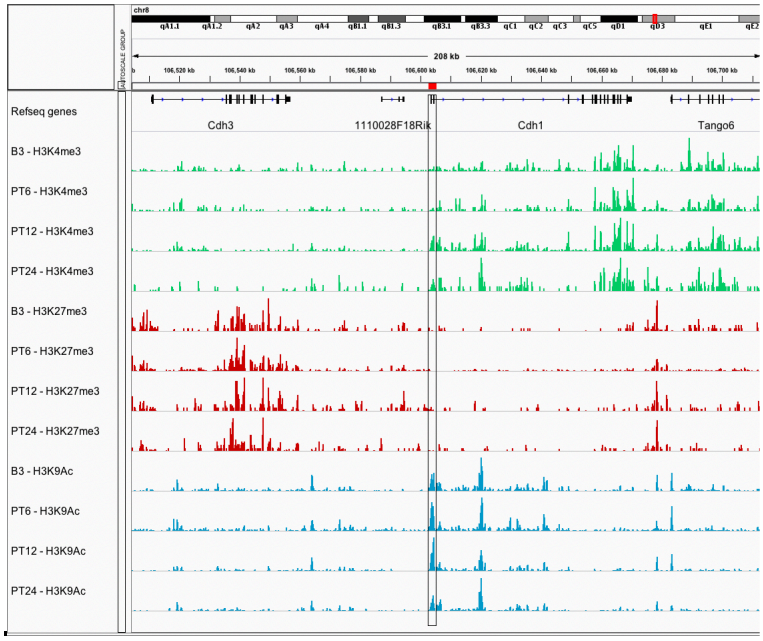

Şekil 6. IGV yazılımının bir ekran görüntüsü: MET sürecinde Cdh1 geninin bulunduğu bölgedeki histon işaretlerinin değişimi.

Aday transkripsiyon faktörü olarak *Grhl3*, *Elf3* ve *Cebpa* seçilmiştir. Bu faktörlere ait hedef genler incelendiğinde birçok ortak genin olduğu (Ahr, Hey1 gibi) saptanmıştır (Şekil 7). GO enrichment analiz sonuçları incelendiğinde; birçoğunun köklülük (stemness), tümorogenez, somatik yeniden programlama, hücre döngüsü, mitoz, kromatin altyapısının düzenlenmesi ve proliferasyon gibi biyolojik süreçler açısından büyük önem arz ettiği görülmüştür.

Şekil 7. Grhl3, Cebpa ve Elf3 tarafından düzenlenen ortak transkripsiyon faktörlerini gösteren Venn diyagramı.

Aday transkripsiyon faktörlerinin genom çapında bağlanma yerlerinin belirlenmesi amacıyla ChIP-Seq analiz yöntemi kullanılmıştır. İleri analizler devam etmektedir.

Referanslar

Alotaibi, H., et al. (2015). "Enhancer cooperativity as a novel mechanism underlying the transcriptional regulation of E-cadherin during mesenchymal to epithelial transition." Biochim Biophys Acta **1849**(6): 731-742.

Antonello, Z. A., et al. (2015). "Mesenchymal to epithelial transition during tissue homeostasis and regeneration: Patching up the Drosophila midgut epithelium." Fly (Austin) **9**(3): 132-137.

Bozzi, F., et al. (2016). "Epithelioid peritoneal mesothelioma: a hybrid phenotype within a mesenchymal-epithelial/epithelial-mesenchymal transition framework." Oncotarget.

Brettingham-Moore, K. H., et al. (2015). "Interplay between Transcription Factors and the Epigenome: Insight from the Role of RUNX1 in Leukemia." Front Immunol **6**: 499.

Cieslik, M., et al. (2013). "Epigenetic coordination of signaling pathways during the epithelial-mesenchymal transition." Epigenetics Chromatin **6**(1): 28.

Fleming, J. D., et al. (2013). "NF-Y coassociates with FOS at promoters, enhancers, repetitive elements, and inactive chromatin regions, and is stereo-positioned with growth-controlling transcription factors." Genome Res **23**(8): 1195-1209.

Gregoire, J. M., et al. (2016). "Identification of epigenetic factors regulating the mesenchyme to epithelium transition by RNA interference screening in breast cancer cells." BMC Cancer **16**: 700.

Kim, H. Y., et al. (2016). "On the role of mechanics in driving mesenchymal-to-epithelial transitions." Semin Cell Dev Biol.

Lamouille, S., et al. (2013). "Regulation of epithelial-mesenchymal and mesenchymal-epithelial transitions by microRNAs." Curr Opin Cell Biol **25**(2): 200-207.

Lamouille, S., et al. (2014). "Molecular mechanisms of epithelial-mesenchymal transition." Nat Rev Mol Cell Biol **15**(3): 178-196.

Lee, J. Y. and G. Kong (2016). "Roles and epigenetic regulation of epithelial-mesenchymal transition and its transcription factors in cancer initiation and progression." Cell Mol Life Sci **73**(24): 4643-4660.

McDonald, O. G., et al. (2011). "Genome-scale epigenetic reprogramming during epithelial-to-mesenchymal transition." Nat Struct Mol Biol **18**(8): 867-874.

Nardini, M., et al. (2013). "Sequence-specific transcription factor NF-Y displays histone-like DNA binding and H2B-like ubiquitination." Cell **152**(1-2): 132-143.

Sengez, B., et al. (2019). "The Transcription Factor *Elf3* Is Essential for a Successful Mesenchymal to Epithelial Transition." Cells. 2019 Aug 9;**8**(8).

Serrano-Gomez, S. J., et al. (2016). "Regulation of epithelial-mesenchymal transition through epigenetic and post-translational modifications." Mol Cancer **15**: 18.

Somarelli, J. A., et al. (2016). "Mesenchymal-Epithelial Transition in Sarcomas Is Controlled by the Combinatorial Expression of MicroRNA 200s and GRHL2." Mol Cell Biol **36**(19): 2503-2513.

Stadler, S. C. and C. D. Allis (2012). "Linking epithelial-to-mesenchymal-transition and epigenetic modifications." Semin Cancer Biol **22**(5-6): 404-410.

Sun, L. and J. Fang (2016). "Epigenetic regulation of epithelial-mesenchymal transition." Cell Mol Life Sci **73**(23): 4493-4515.

Tam, W. L. and R. A. Weinberg (2013). "The epigenetics of epithelial-mesenchymal plasticity in cancer." Nat Med **19**(11): 1438-1449.

ULUSLARARASI HASTALIK SINIFLANDIRMASINDA YENİ REVİZYON: ICD-11

Filiz İşleyen[1], Berrak Bora Başara[1], M. Mahir Ülgü[1]

[1] T.C. Sağlık Bakanlığı, Sağlık Bilgi Sistemleri Genel Müdürlüğü, Ankara, Türkiye.
filiz.isleyen@saglik.gov.tr

Abstract.

WHO announced that the 11th revision of the ICD could be used. A different method was used in the coding system by conducting a different study from the previous revisions of ICD-10. Firstly, the number of sections in ICD-11 was increased and the codes under the sections were changed. In ICD-10, for example, a code under section 5 may be classified under section 7 of ICD-11. New classification systems such as ICD-O, device names and names of body parts have been added to ICD-11. The ICD-11 also uses synonyms or abbreviations for the terms to be searched in order to identify diagnostic codes easily. In addition, web services have been developed for use in information systems with electronic coding tool. WHO has developed electronic solutions so that the new revision of the ICD can be easily used and harmonized through information technologies. In conclusion, the 11th Revision of the ICD can be considered a major step forward for health care worldwide, as it covers all factors that affect health as well as diseases.

Keywords: ICD-10, ICD-11, International Classification of Diseases.

Özet.

DSÖ tarafından ICD'nin 11. revizyonunun kullanılabileceği açıklanmıştır. Kodlama sisteminde önceki revizyonlardan farklı bir yöntem kullanılmıştır. İlk olarak, ICD-11'deki bölümlerin sayısı arttırılmış ve bölümlerin altında bulunan kodlar değiştirilmiştir. Örneğin, ICD-10'da, bölüm 5 altında bulunan bir kod, daha uygun olduğu düşünülerek ICD-11'de 7. bölümde sınıflandırılmıştır. ICD-11'e, ICD-O, tıbbi cihaz adları ve vücutta bulunan organların adları gibi yeni kodlar eklenmiştir. ICD-11 ayrıca, teşhis için kullanılan kodları kolayca bulabilmek için kelimelerin eşanlamlılarını veya kısaltmalarını da kullanmıştır. Buna ek olarak, bilgi sistemlerinde kullanımını kolaylaştırmak amacı ile elektronik kodlama aracı geliştirilmiştir. DSÖ, ICD-11'in bilgi teknolojileri aracılığıyla kullanılabilmesi için tamamen elektronik çözümler geliştirmiştir. Sonuç olarak ICD'nin 11. Revizyonu, hastalıkların yanı sıra sağlık durumunu etkileyen tüm faktörleri kapsaması nedeniyle dünya çapında sağlık için atılmış büyük bir adım olarak değerlendirilebilir.

Anahtar Kelimeler: ICD-10, ICD-11, Uluslararası Hastalık Sınıflandırması.

1 Giriş

Uluslararası Hastalık Sınıflandırması ve İlgili Sağlık Sorunları (ICD-The International Classification of Diseases and Related Health Problems-ICD), mortalite ve morbidite verilerinin sistematik olarak kayıt altına alınması, raporlanması, analiz edilebilmesi, yorumlanması ve diğer ülkelerle karşılaştırılması için Dünya Sağlık Örgütü (DSÖ) tarafından geliştirilmiş uluslararası bir standarttır. Günümüzde Türkiye dahil bir çok ülkede hastalıkların sınıflandırılması için ICD kodları kullanılmaktadır. ICD sisteminin, ilk geliştirilmeye başlandığı zamandan itibaren revizyonları yapılmaktadır. ICD'nin 11. revizyonu (ICD-11) için birçok farklı ülkeden klinisyenler, istatistikçiler, epidemiyologlar, kodlayıcılar, sınıflandırma ve bilgi teknolojileri uzmanlarıyla birlikte çalışılarak, bilimsel içerik güncellenmiş, tüm klinik detayların kodlanmasını sağlayan, ilgili sınıflandırma ve terminolojilerle ilişkili, kullanılabilirliği geliştirilmiş, elektronik ortamlarda kullanıma hazır bir sistem geliştirilmiştir [1].

Bilgi teknolojilerinin gelişmesi ve her alanda olduğu gibi sağlık alanında da kullanımının yaygınlaşması ile birlikte ICD-11'in bilgi sistemlerinde kullanımına ilişkin de çözümler geliştirilmiştir. Ülkemizde şu anda ICD 10. Revizyon kodları kullanılmakta olup bu kodların bilgi sistemlerinde kullanılması için gerek T.C. Sağlık Bakanlığı sistemlerinde gerekse sağlık hizmeti sunucularında faaliyet gösteren sağlık bilgi sistemi yazılımlarında yeni düzenlemeler yapılması gerekmiştir. ICD için önceki revizyonlardan farklı olarak ilk defa, 11. revizyon tamamen elektronik olarak yayımlanmış ve hali hazırda 100.000'in üzerinde tıbbi teşhis endeksi terimi ile 17.000 teşhis kategorisine erişim sağlanmaktadır [1].

ICD-10'da 21 bölüm mevcutken ICD-11'de 26 bölüm bulunmaktadır ve ICD-10 ile karşılaştırıldığı zaman bu bölümlerde bulunan kodların bir kısmının ilgili başlığının değiştiği, bazılarının yeni bölüm başlığı altına eklendiği bazılarının ise daha önce sınıflandırılmamış ancak günümüzde kullanılmakta olan tanılar olduğu görülmektedir [2]. ICD-11, Mayıs 2019'da gerçekleşen 72. Dünya Sağlık Meclisi'nde (72. World Health Assemble) onaylanarak 1 Ocak 2022 tarihi itibariyle tüm üye ülkelerde kullanımına başlanacağı kararı alınmıştır [3].

Bu çalışmanın amacı tüm DSÖ'ye üye ülkelerde kullanılmaya başlanması onaylanan ICD-11 hakkında genel bir bilgi vermek, ICD-11 ile ICD-10 farklılıklarını belirtmek ve DSÖ tarafından önerilen kullanım yöntemine ilişkin açıklamalarda bulunmaktır.

2 ICD-11'deki Yenilikler

ICD-11'e beş yeni bölüm eklenmiştir;

- Bölüm 3 - Kan veya Kan Yapıcı Organların Hastalıkları
- Bölüm 4 - İmmün Sistem Bozuklukları
- Bölüm 7 - Uyku-Uyanma Bozuklukları
- Bölüm 17 - Cinsel Sağlık ile İlgili Koşullar
- Bölüm 26 - Geleneksel Tıp

Buna ek olarak "Ek Bölüm" başlığı altında
Ek bölüm V - İşlevselliğin değerlendirilmesi ve

Ek bölüm X - Extension (Genişletilmiş=özelleştirilmiş) kodlar (sağ, sol, organların yeri vb.) olmak üzere iki yeni bölüm daha eklenmiştir.

ICD-11'de bulunan yeniliklerden biri bazı tanıların bölümlerinin değiştirilmiş olmasıdır. Örneğin "İnme" tanısı daha önceden "Dolaşım Sistemi" başlığı altında bulunmaktayken ICD-11'de "Sinir Sistemi Hastalıkları" başlığı altında sınıflandırılmıştır.
Bazı hastalıklar ise başka bir başlık altında iken ICD-11'de yeni oluşturulan başlıkların altında sınıflandırılmıştır. Örneğin "Cinsel Uyumsuzluk" daha önce zihinsel hastalıklar altında iken 11. revizyondan sonra yeni eklenen "Cinsel Sağlık ile İlgili Koşullar" bölümünde sınıflandırılmıştır. Bu da cinsel uyumsuzluk sorununun sadece zihinsel bir sağlık sorunu olmadığı anlayışını yansıtmaktadır.

ICD-11'de daha önceden hastalık olarak kabul edilmeyen veya uluslararası olarak sınıflandırılmayan yeni hastalıklar da eklenmiştir. Örneğin internetin sadece kişisel bilgisayarlarda değil aynı zamanda cep telefonu, tablet gibi mobil cihazlarda da kullanılabilir olmasıyla birlikte internet üzerinden oynanan oyunların sayısında geçmişe kıyasla bir artış bulunmaktadır. Bu oyunların erişiminin kolaylığı veya çeşitliliğinin artması ise son dönemde oyun oynayan bireylerin sayısında da artışa neden olmuştur. Yapılan çalışmalar, zamanının büyük bir kısmını oyunlara harcayan bireylerin fazlalığını ve onların oyun bağımlılığını ortaya koymaktadır[4]. Böylelikle artık günümüzde bir hastalık olarak kabul edilen "Oyun Hastalığı" ICD-11 ile birlikte sınıflandırma sistemine de girmiş bulunmaktadır.

Tablo 1. ICD-11'in Genel Özellikleri

ICD-11 Terimleri	Açıklama
Temel (Foundation)	ICD-11 tablo listesinin yazdırma sürümlerini ve alfabetik dizini oluşturmak için gerekli tüm bilgileri içeren ve aynı zamanda ICD-11'in özel sürümlerini ve ülkeye özgü değişiklikleri üretmek için gereken ek bilgileri içeren veri tabanı içeriğidir.
Kök Kodu (Stem code)	Yalnız kullanılabilecek kodlardır. Mortalite ve Morbidite İstatistikleri için ICD-11 tablosunda bulunmaktadır. Bunlar, her zaman tek bir kategori olarak tanımlanması gereken varlıklar, gruplar veya klinik koşullar olabilir. Her vaka için sadece bir kod gerektiren kullanım durumlarında, kodun, asgari miktarda da olsa tanıya özel minimum bilgiyi içerdiğinden emin olunmalıdır.
Uzatma kodu (Extension code)	Bazı kullanıcılar veya vakaya özel durumlar için, konulan tanının kök kod tarafından verildiğini bildirmek için daha fazla ayrıntı gerekir. Bu ilave detay bir uzatma kodu kullanılarak kodlanabilir. Örneğin tanı için sağ gözde enfeksiyon yazılacaksa "sağ" uzatma kodları arasından seçilmelidir. Bir uzatma kodu, hiçbir zaman bir kök kodu olmadan kullanılamaz, aksine, bildirilen bir durumu tam olarak tanımlamak için birlikte kullanılırlar.
Küme kodlama (Cluster coding)	Kök kodlar, bir koşulu tam olarak tanımlamak için uzatma kodlarıyla veya diğer kök kodlarıyla birlikte koordine edilebilir veya birlikte kullanılabilir. Bu durumlarda, koordine sonrası kodlar, hangilerinin hastalığı tanımlamak için birbirine ait olduğunu göstermek için birlikte gruplandırılacaktır; bu mekanizmaya 'küme kodlaması' denir.

Birincil ve ikincil ebeveynler (Primary and secondary parents)	ICD-11, ICD'nin önceki revizyonları ile benzer hiyerarşik düzendedir. Ancak sınıflandırma içerisindeki spesifik hastalıklar ve kavramlar başka bir ana koda da bağlanabilecek şekilde sınıflandırma yapılmıştır. Örnek: Kemoterapiye bağlı kronik ağrı tanısı için hem "kronik kanser ağrısı" hem de "kronik nöropatik ağrı" bölümleri ebeveyn (parent) olarak tanımlanabilir. Bu durumda bu iki bölümden birinin birincil ebeveyn olarak tanımlanması gerekmektedir. Ancak "kemoterapiye bağlı kronik ağrı" tanısı her iki başlık altında da bulunabilir.

AA00 kodu, Dış Kulak Apse (Abscess of external ear) tanısı için tek başına yazılabilir ancak ağrı sadece sağ kulakta ise bir uzatma kod (XK9K - Sağ) eklenerek AA00&XK9K ″sağ kulakta dış kulak apse" tanısı olarak kodlanmalıdır ki burada kümeleme yapılarak kök kod uzatma kodu ile birlikte kullanılmıştır. Bazen bir hastalığın başka bir hastalıkla birlikte görülmesi durumunda ise kök kodların birlikte yazılması gerekebilir. Örneğin, hasta diyabetik komada bir hastaneye yatırılmış ve hastada aynı zamanda Tip 2 şeker hastalığı (diabetes mellitus) hastalığı vardır. Bu durumda; ilk atanması gereken tanı: 5A23 Diyabetik koma, ikinci tanı ise; 5A11 Tip 2 şeker hastalığı ve ICD-11'e göre bu iki kök kod için küme sırası: 5A23 / 5A11 şeklinde olmalıdır [1].

3 ICD-11 ve ICD-10 Kodları Arasındaki Temel Farklılıklar

ICD-11, ICD-10 ile karşılaştırıldığında özellikle kod sayısındaki artışla farklılık göstermektedir. ICD-10'da 14.400 olan kod sayısı, ICD-11'de yaralanma, hastalık ve ölüm nedeni için eklenen kodlar ile 55.000 sayısına ulaşmıştır. ICD-11'e birçok yeni bölüm eklendiği ve bazı hastalıkların bulundukları bölümlerin değiştiği gibi farklılıklardan yukarıda bahsedilmiştir. Ancak ICD-11 sınıflandırma sisteminde bulunan en büyük farklılık kodlama sisteminin tamamen değişmesidir. Kodlama sistemindeki temel farklılıklar Tablo 2'de sunulmuştur.

Tablo 2. ICD-11 &ICD-10 Kod Yapısındaki Temel Farklar

ICD-10	ICD-11
C50.9 Malignant neoplasm of breast, Breast, unspecified	**2C6Z** (Malignant neoplasms of breast, unspecified)
Kodun ilk karakteri bir harftir ve bölüm numarasıyla ilişkili değildir.	Kodun ilk karakteri daima bölümle ilgilidir. 1-9 bölümleri arasında ilk karakter 1-9 arasındaki bir rakam, 10-27 arasındaki bölümler için ilk karakter bir harftir.
Kodun ilk karakteri bir harf, ikinci, üçüncü ve dördüncü karakterleri bir rakam olan alfa sayısal kod yapısı vardır. Noktadan sonra en fazla bir karakter kullanılmıştır.	Kodlar 1A00.00 ila ZZ9Z.ZZ aralığını kapsar. "0" ve "1" rakamları ile karışıklığı önlemek için "O" ve "I" harfleri kullanılmamıştır. Noktadan sonra en fazla iki karakter kullanılmıştır.

ICD-10'da sadece tanı kodları mevcuttur.	ICD-11'de tanı kodlarına ek olarak, lateralite, bölge ve histopatoloji kodları da bulunmaktadır.

DSÖ ICD-11'in ICD-10 ile ilişkisini gösteren bir harita (mapping) da hazırlamıştır. Buna göre ICD-10 kodları ile ICD-11 kodları ilişkilendirilmiştir. Ancak liste incelendiğinde; bir ICD-10 koduna birden fazla ICD-11 kodu karşılık gelebilmektedir (Tablo 3). ICD-11'e geçişte sağlık personeli alışkın olduğu ICD-10 kodları arasından seçim yapmak isteyebilir. Bu durumda ICD-11&ICD-10 haritasının kullanılması faydalı olacaktır. Örneğin sağlık personeli ICD-10'da "E10.0" kodunu seçmek istediğinde ICD-11 kod listesinden de 5A23, 5A20, 5A22.3 kodlarından tanısına en uygun kodu seçmesi istenebilir.

Tablo 3. ICD-10 & ICD-11 Harita Tablosu Kesiti

ICD-10	**ICD-10 Bölümü**	**ICD-10 Tanı Adı**	**ICD-11**	**ICD-11 Bölümü**	**ICD-11 Tanı Adı**
E10-E14	IV	Şeker hastalığı	5A44	05	İnsülin direnci sendromları
E10	IV	Tip 1 Şeker hastalığı	5A10	05	Tip 1 Şeker hastalığı
E10.0	IV	Koma ile Tip 1 Şeker hastalığı	5A10	05	Tip 1 Şeker hastalığı
E10.0	IV	Koma ile Tip 1 Şeker hastalığı	5A23	05	Diyabetik koma
E10.0	IV	Koma ile Tip 1 Şeker hastalığı	5A20	05	Diyabetik hiperosmolar hiperglisemik durum
E10.0	IV	Koma ile Tip 1 Şeker hastalığı	5A22.3	05	Koma ile diyabetik ketoasidoz

***Tablo 3'te sunulan veriler DSÖ tarafından https://ICD.who.int/browse11/l-m/en bağlantısında sunulmaktadır.**

4 ICD-11 Bileşenleri

4.1 Tarayıcı

ICD-11'in tüm üye ülkelerde elektronik olarak kullanılabilmesi ve bilgi sistemlerine entegrasyonunu kolaylaştırmak için bazı bileşenler geliştirilmiştir. Bunlardan biri ICD-

11 tarayıcısıdır (ICD-11 Browser). Kullanıcılar tarayıcı ile istedikleri tanı kodunu bulabilir, tanı kodunun ICD-11 bölümleri ile ilgili olarak hangi ilişkilendirmelerde olduğunu görebilir (https://icd.who.int/browse11/l-m/en).

4.2 Kodlama Aracı

Bir diğer önemli bileşen ise kodlama aracıdır (coding tool). Kodlama aracında arama kutucuğuna kullanıcı bir terim yazdığında -örneğin "Neoplazma"-, bu terimin bulunduğu üç farklı sonuç listesi oluşturulur. Birincisi; aranan terim ile başlayan veya içinde aranan terimin geçtiği kelimelerin olduğu bir kelime listesidir. İkincisi; aranan terim için sistem tarafından önerilen tanı listesidir ki bu listeden tarayıcı ile doğrudan bağlantı bulunmaktadır. Üçüncüsü ise ICD-11 bölümlerinde aranan terim ile ilgili bölümlerin listesidir [5] Şekil-1.

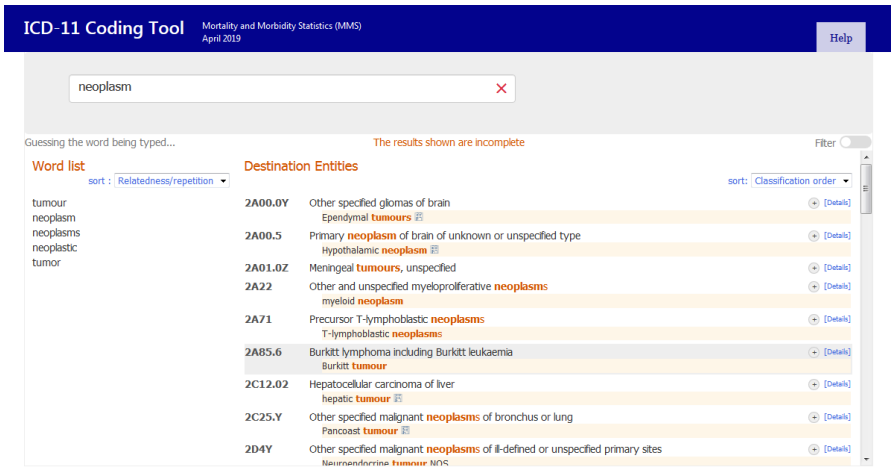

Şekil 1. Kodlama Aracı

4.3 Temel veri tabanı

ICD-11 veri tabanında; ICD-11 kodları, hastalıklar, yaralanmalar, tıbbi cihaz isimleri, hastalık isimlerinin eş anlamlıları listesi, kısaltma listesi vb. birçok bileşen bulunmaktadır. ICD-11 kodlama aracının kullanılması için geliştirilen kurallar bu veri tabanını kullanmaktadır. Örneğin kodlama aracında "neoplasm" kelimesi arandığında, veri tabanında eşleştirildiği için "tumor" kelimesinin de geçtiği kelime veya kelime öbekleri listelenmektedir [5]. Böylece kullanıcılar aradıkları hastalığın ya da kelimenin tam olarak sistemde nasıl bulunduğunu bilmek zorunda kalmamakta ve aramalarında büyük bir kolaylık ve hız sağlanmaktadır.

4.4 Çeviri Aracı

DSÖ'ye üye ülkelerin ICD-11'i kendi dillerinde kullanabilmeleri için bir çeviri platformu geliştirilmiş ve çevrimiçi olarak kullanıcıların hizmetine sunulmuştur. Platformun kullanımına ilişkin koşullarda, DSÖ Genel Merkezine tercüman olarak kullanıcı kaydı yapılmasını gerektiren bir koşul bulunmaktadır. Platform aynı ülkeden bir tercüman tarafından yapılan çevirilerin diğer tercümanlar tarafından da görülmesine izin vermektedir. Bir çevirinin onaylanması için birden fazla tercümanın onayının olması gerekmektedir, bu da yapılan çevirilerin şeffaf ve doğrulanmış olduğunu göstermektedir.

4.5 Uygulama Programlama Arayüzü

ICD-11'in sağlık tesislerinde kullanılan Sağlık Bilgi Yönetim Sistemlerinde (SBYS) kullanılması için Application Programming Interface (API) geliştirilmiştir. SBYS'ler ile API entegrasyonu yapıldığında, SBYS DSÖ tarafından geliştirilen kodlama aracını kendi sistemine entegre edebilecek ve kullanıcının kod seçimi yapmasıyla API'ın aradan çekilerek seçim yapılan ICD-11 kodu SBYS veri tabanına kayıt edilebilecektir [1]. Bu da ülkelerin kendi kural listesini oluşturmak zorunda kalmayacağı anlamına gelmektedir. DSÖ'ye üye ülkeler API entegrasyonunu yapmak zorunda olmamakla birlikte entegrasyon yapılmadığı durumlarda, DSÖ tarafından oluşturulan kural setlerini, eşanlamlılar listesini veya diğer araçları elektronik olarak kullanabilmeleri için kendi çözümlerini geliştirmek zorunda kalacaklardır. Bu da hali hazırda var olan kural setlerinin yeniden oluşturulması, bunların doğrulatılması yani oldukça uzun bir süreç anlamına gelmektedir. Bu nedenle önerilen, önce çevirilerin yapılması ve sonrasında API entegrasyonu ile tüm araçların elektronik olarak kullanılmasının sağlanması şeklindedir.

5 Sonuç

DSÖ, 25 Mayıs 2019'da 72. Dünya Sağlık Meclisi'nde kabul edilmesinin ardından ICD-11'in kullanılmaya hazır olduğunu duyurmuştur [3].
T.C. Sağlık Bakanlığı, ICD-11 ile ilgili çalışmalara etkin bir şekilde katılmaktadır. ICD-11 beta versiyonu için tüm paydaşlardan görüşlerini ICD-11 sekretaryasına iletmelerini istemiş ve konuyla ilgili yapılan toplantılara katılım sağlayarak ülkemizde ICD-11'e geçiş için bir yol haritası belirlemeye yönelik çalışmalarını başlatmıştır. Bu kapsamda yapılması gereken öncelikli iş, DSÖ tarafından da önerildiği gibi ICD-11 için DSÖ'nün hazırladığı materyallerin Türkçeye tercümesinin yapılmasıdır. Tercüme yapılırken tıbbi terimlerin eşanlamlarının, kısaltma listelerinin hazırlanması (bu süreçte tıbbi uzmanlık derneklerinden destek alınabilir), hekimlere ve tıbbi personele ICD-11 kullanımına yönelik eğitimlerin verilmesi, SBYS'lerde kolay kullanım için API entegrasyonun yapılması gerekmektedir. Bu süreçte T.C. Sağlık Bakanlığı koordinasyonunda konuyla ilgili tüm paydaşların etkin bir şekilde görev almaları ülkemizin ICD-11'e geçişini kolaylaştıracaktır.

Sonuç olarak ICD'nin 11. Revizyonu, hastalıkların yanı sıra sağlık durumunu etkileyen diğer faktörleri de kapsaması nedeniyle dünya çapında sağlık için atılmış büyük bir adım olarak değerlendirilebilir. Aynı zamanda ICD-11'in tamamen elektronik olma özelliği, uygulamaya yardımcı olacak, tanıdaki hataları azaltacak ve ülkelere özel eş anlamlılar ve kısaltmalar listelerinin veri tabanına eklenebilmesi ile ülkeler için daha kullanılabilir olacaktır.

Kaynaklar

1. WHO, «ICD-11 Implementation or Transition Guide,» World Health Organization, Geneva, 2019.
2. WHO, «ICD-11 Reference Guide,» Geneva, 2019.
3. WHO, Newsroom/Detail/World Health Assembly Update, 25 May 2019, 2019. [Çevrimiçi]. Available: https://www.who.int/news-room/detail/25-05-2019-world-health-assembly-update. [Erişildi: 11 09 2019].
4. Irmak A.Y, Erdoğan, S., «Ergen ve Genç Erişkinlerde Dijital Oyun Bağımlılığı,» *Türk Psikiyatri Dergisi* , cilt 2, no. 27, pp. 128-37, 2016.
5. WHO, «ICD-11 Coding Tool,» WHO, 04 2018. [Çevrimiçi]. Available: https://icd.who.int/ct11_2018/icd11_mms/en/release#/. [Erişildi: 10 09 2019].

SUALTI RAGBİSİ İÇİN OYUNCU TAKİP VE ANALİZİ

Ozan Konur[1], M. Alper Selver[2] ve Levent Çavaş[3]

[1] Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü
[2] Dokuz Eylül Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Bölümü
[3] Dokuz Eylül Üniversitesi, Fen Fakültesi, Kimya Bölümü

Özet. Günümüzde spor aktiviteleri için en önemli etkenlerden biriside oyuncu analizleridir. Birçok spor dalında, oyuncuların analizleri ve bu analizlere dayalı verilerin işlenmesi ile birlikte elde edilen deneyim sayesinde, oyuncularda performans artışı sağlanmaktadır. Herbir oyuncu için sağlanan performans artışları doğrudan takım performansını etkileyerek takımın performansın artışını gerçekleşmektedir. Birçok spor dalında gerçekleşen bu performans ölçümlerinin en önemli uygulamaları futbol, basketbol gibi alanlarda yapılmaktadır. Farklı methodlar ile gerçekleşen ölçümlerde, maç sırasında eş zamanlı veri akışı yanısıra, maç sonrasıda yapılan ölçümler ile oyuncu bazında yada takım olarak performans ölçümleri yapılmaktadır. Bu projede, yapılan uygulamaların su altında uygulanabilirliği üzerine geliştirmeler yapılmaktadır. Su altında oynanan bir spor dalı olan sualtı ragbisi oyununda, oyuncu analizleri için günümüz teknolojilerinin uygulanabilirliği ölçümlenmeye çalışılmıştır. Gerçekleştirilecek ölçümler sonucunda sualtı ragbi oyuncuları için performans artışı sağlanması ve elde edilen oyuncu verilerine göre, oyuncu için gerekli geliştirmeler kolay bir şekilde belirlenebilecektir. Bu kapsama yönelik oyuncu takibi ve analizi için resim işleme ve giyilebilir donanım üzerinde durulacaktır. Bu metodların uygulanabilirliği ve zorlukları üzerine çıkarım yapılacaktır.

Anahtar Kelimeler: Sualtı ragbisi, oyuncu takip ve analizi, sualtı sporları.

Mobil Sağlık Uygulamalarında Kullanılabilirlik: Göz İzleme Teknolojileri

Hasibe Yıldız[1] and Neşe Zayim[1]

[1] Akdeniz Üniversitesi, Antalya, Türkiye
yildizhasibe@hotmail.com

Abstract

The rapid spread of smartphones today has brought the idea of being able to benefit from these devices through mobile health applications. With the introduction of mobile applications in the field of health, the availability of these technologies needs to be evaluated to ensure the safety of the user and improve patient and community health outcomes.

Human-Computer Interaction (HCI), close to computer systems, may be thought to have a large cognitive component, as it involves the processing of information by humans. It is important in the development of health information systems to provide information about human cognitive processes, what typical system users can do and what cannot be expected from users, identify and explain the nature and cause of user problems, characterize the problem-solving and decision-making processes of health workers, to evaluate the cognitive needs of users in designing systems and user interfaces, feedback on system redesign and improvement and providing models and frameworks for conducting HCI research in health care.

Eye-tracking technology, used to measure human cognitive processes, has the potential to improve the availability of health information technology (HIT), which improves quality, patient safety, and efficiency in health systems. The eye-tracking method, which is useful in detecting usability problems in many ways, has not yet become widespread in measuring the availability of health information technologies. The aim of this study is to review the potentials of eye-tracking technologies in the evaluation of the usability of eye-tracking technologies and the usability of mobile health applications.

Özet

Günümüzde akıllı telefonların hızla yaygınlaşması, sağlık alanında da mobil sağlık uygulamaları aracılığıyla bu cihazlardan faydalanabilme fikrini beraberinde getirmiştir. Mobil uygulamaların sağlık alanında kullanılmaya başlanmasıyla birlikte bu uygulamaların kullanıcının güvenliğini sağlamak ve hasta ve toplum sağlığı sonuçlarını iyileştirmek için bu teknolojilerin kullanılabilirliğinin değerlendirilmesi gerekmektedir.

İnsan-Bilgisayar Etkileşiminin (İBE), bilgisayar sistemleriyle yakın bir şekilde, bilgilerin insanlar tarafından işlenmesini içerdiği için büyük bir bilişsel bileşene sahip olduğu düşünülebilir. İnsanın bilişsel süreçleri bilgisi, tipik sistem kullanıcılarının neler yapabileceği ve kullanıcılardan nelerin beklenemeyeceği hakkında bilgi sağlamak, kullanıcı problemlerinin niteliğini ve nedenini belirlemek ve açıklamak, sağlık çalışanlarının problem çözme ve karar verme süreçlerini karakterize etmek, kullanıcıların sistem ve kullanıcı ara yüzlerini tasarlamada bilişsel ihtiyaçlarını değerlendirmek, sistemin yeniden tasarlanması ve iyileştirilmesine geri besleme ve sağlık hizmetlerinde HCI araştırmalarını yürütmek için modeller ve çerçeveler sunmak gibi bir çok yolla sağlık bilgi sistemlerinin geliştirilmesinde önemlidir.

İnsan bilişsel süreçlerini ölçmek için kullanılan göz izleme teknolojisi, sağlık sistemlerinde kalitenin, hasta güvenliğinin ve verimliliğin arttırılmasını sağlayan sağlık bilgi teknolojisinin (HIT) kullanılabilirliğini geliştirme potansiyeline sahiptir. Kullanılabilirlik problemlerini birçok yönden tespit etmekte faydalı olan göz izleme yöntemi, sağlık bilgi teknolojileri kullanılabilirliğinin ölçülmesinde henüz yaygınlaşmamıştır. Bu çalışmasının amacı, göz izleme teknolojilerini ve mobil sağlık uygulamalarının kullanılabilirlik değerlendirmelerinde göz izleme teknolojilerinin potansiyellerini gözden geçirmektir.

Keywords: Mobil Sağlık Uygulamaları, Kullanılabilirlik, Göz izleme yöntemi, Eye-tracking

1 Mobil Sağlık Uygulamalarında Kullanılabilirlik

Kullanılabilirlik, Uluslararası Standardizasyon Örgütü (ISO) Standardı'na dayanarak, kullanıcıların etkin, verimli ve memnuniyetle bir hedefe ulaşma derecesidir. Kullanılabilirlik geniş anlamda, kullanıcıların görevlerini güvenli, etkin, verimli ve zevkli bir şekilde yerine getirmelerine izin verecek bir kapasite olarak tanımlanabilir [1, 2].

Kullanılabilirlik 5 kalite bileşeniyle tanımlanır:

- Öğrenilebilirlik: Kullanıcıların ara yüzü ilk kez kullandıklarında temel görevleri yerine getirmeleri ne kadar kolaydır?
- Verimlilik: Kullanıcılar tasarımı öğrendikten sonra, görevleri ne kadar hızlı gerçekleştirebilir?
- Geri çağırma: Kullanıcılar, bir süre sonra kullanmadıkları tasarıma döndüklerinde, yeterliliklerini ne kadar kolay bir şekilde sağlayabilirler?
- Hatalar: Kullanıcılar kaç hata yapar, bu hatalar ne kadar ciddidir ve hatalardan ne kadar kolay kurtulabilirler?
- Memnuniyet: Kullanıcılar tasarımı kullanmaktan ne kadar memnun? [3]

Mobil teknoloji uygulamaları, hastalar ve aileleri için kronik durumların kendi kendine yönetimi yoluyla sağlığı iyileştirme stratejisi olarak yaygın bir şekilde tanıtılmıştır. Günlük davranışları ve sonuçta sağlık sonuçlarını iyileştirmek için diyet, egzersiz, ilaç uyumu veya sağlıkla ilgili diğer görevler gibi sağlık davranışlarındaki kişisel eğilimleri

izlemek için uygulamalar aracılığıyla hastanın ürettiği verilerin kullanılmasına yönelik bir hareket vardır. Akıllı telefonların ve mobil sağlık uygulamalarının, bireylerin sağlığını, hasta sağlığı sonuçlarını ve toplum sağlığını iyileştirmede önemli katkısı olduğu kabul edilmektedir [4]. Sağlık hizmetleri, tedavi planlarını iyileştirmek için evde kullanılan kan şekeri veya kan basıncı gibi hasta tarafından oluşturulan verileri elektronik sağlık kaydına entegre etmek için uygulamaların kullanımıyla giderek daha fazla ilgilenmeye başlamıştır.

Sağlık hizmetlerinde yeni bilgi teknolojisinin kullanılması, uygun şekilde tasarlanmadığında istenmeyen tıbbi hataları artırma potansiyeline de sahiptir [5]. Vatandaşların ve sağlık profesyonellerinin sağlık etkinlikleri için yeniden yapılandırdığı mobil donanım ve yazılımlar hatalar doğurabilir; örneğin, cep telefonlarındaki otomatik tamamlama işlevi, bir cep telefonunda not alan uygulamaya yazılırken (eğer otomatik tamamlama ilaç adını değiştirirse) kaydedilmekte olan bir ilacın isminin yanlış girilmesine yol açabilir [6, 7].

Mobil uygulamaların sağlık alanında kullanılmaya başlanmasıyla birlikte bu uygulamaların tıbbi hatalara neden olduğu göz önünde bulundurularak kullanıcının güvenliğini sağlamak ve hasta ve toplum sağlığı sonuçlarını iyileştirmek için bu teknolojilerin kullanılabilirliğinin değerlendirilmesi gerekmektedir [6, 4, 8, 9].

Sağlık bilgi sistemlerinin, biliş ve insan bilgi işlemeyle ilişkili birçok yönü vardır. Bu nedenle, HCI (Human-Computer Interaction)'nin, bilgisayar sistemleriyle yakın bir şekilde, bilgilerin insanlar tarafından işlenmesini içerdiği için büyük bir bilişsel bileşene sahip olduğu düşünülebilir. İnsanın bilişsel süreçleri bilgisi, tipik sistem kullanıcılarının neler yapabileceği ve kullanıcılardan nelerin beklenemeyeceği hakkında bilgi sağlamak, kullanıcı problemlerinin niteliğini ve nedenini belirlemek ve açıklamak, sağlık çalışanlarının problem çözme ve karar verme süreçlerini karakterize etmek, kullanıcıların sistem ve kullanıcı ara yüzlerini tasarlamada bilişsel ihtiyaçlarını değerlendirmek, sistemin yeniden tasarlanması ve iyileştirilmesine geri besleme ve sağlık hizmetlerinde HCI araştırmalarını yürütmek için modeller ve çerçeveler sunmak gibi bir çok yolla sağlık bilgi sistemlerinin geliştirilmesinde önemlidir [10]. İnsan bilişsel süreçlerini ölçmek için kullanılan göz izleme teknolojisi, sağlık sistemlerinde kalitenin, hasta güvenliğinin ve verimliliğin arttırılmasını sağlayan sağlık bilgi teknolojisinin (HIT) kullanılabilirliğini geliştirme potansiyeline sahiptir.

2 Göz izleme (eye-tracking)

Göz hareketlerinin araştırılması 19. yüzyıla dayanmaktadır. Java 1879 yılında okuma esnasındaki gözün hızlı hareket etmesini Fransızca'da 'ani, düzensiz hareketler' anlamına gelen 'saccadé' olarak adlandırmıştır. Dodge 1916 yılında 'saccade' kelimesini okuma esnasında ortaya çıkan hızlı göz hareketleri olarak çalışmalarına yansıtmıştır [11].

İlk çalışmalar kapsamında göz içine doğrudan yerleştirilen cisimler aracılığıyla invazif olarak göz hareketleri tespit edilebilmekteydi. Kullanıcı için oldukça rahatsız edici olan

bu yöntem, yerini Dodge ve Cline tarafından 1901 yılında bulunan korneadan yansıyan ışığın kullanılmasıyla ilk invazif olmayan göz izleme tekniğine bıraktı. Bu tekniklerin kullanımı esnasında göz hareketlerinin izlenebilmesi için başın sabit tutulması gerekmekteydi. 1948 yılında Hartridge and Thompson göz hareketleri izlenen kullanıcının başına takılarak kullanılan bir cihaz geliştirerek başın hareket etme kısıtını azalttı. İlerleyen yıllarda bu cihaz geliştirilerek daha kullanışlı bir hale getirildi. 1970'li yıllarda bu teknik psikoloji ve fizyoloji alanlarında kullanılmaya başlanarak gözün işleyişi, algısal ve bilişsel süreçler hakkında yapılan araştırmalarda kendine yer edindi [12].

Teknolojinin gelişmesi ve bilgisayar kullanımının yaygınlaşmasıyla göz izleme yöntemi, görsel uyaranlarla dikkat mekanizmaları arasındaki yakın ilişki sebebiyle [13] insan-bilgisayar etkileşimini incelemenin yanında arayüzlerin kullanılabilirliğini değerlendirmek için de kullanılmaya başlandı.

İnsan bilgi işlem teorisine göre insanlar, zihinsel kaynaklarının sınırlı olması nedeniyle, aynı anda yalnızca belirli bir miktarda görsel uyarana dikkatini verebilirler [14]. Aşırı bilgi uyaranları, göz bebeği çapı değişikliği gibi fizyolojik belirtiler gösteren aşırı zihinsel yüklenme ile sonuçlanacaktır [15]. Gözün bir noktaya odaklanma süresi, göz kırpma sayısı, pupil çapı ölçme yöntemleri yanında insan gözünden yansıyan kızılötesi ışığı analiz edilerek de kullanıcının zihinsel yükü ve bilişsel durumu tespit edilebilmektedir [16]. Bu yöntemle kullanıcı arayüzünde, kullanıcıların dikkatini çekebilecek ve insan beyni tarafından işlenebilecek alanlar da tespit edilebilmektedir [17].

Göz izleme ölçümleri, katılımcının bakışlarının görsel ara yüzdeki ilgili öğenin konumuyla çakışıp çakışmadığını, ara yüzün çeşitli bileşenlerine ne kadar süre odaklandığını, belirli bir ilgi alanına kaç kere baktığını, aramalarının stratejik olup olmadığı gösterebilir [18]. Göz hareketleri aslında otomatik veya reflekse dayalı olarak gerçekleşmemekte, beyin tarafından yürütülen karar sürecini temsil etmektedir [19]. Göz takibi yoluyla, sadece birkaç milisaniyede ortaya çıkan karmaşık bilişsel süreçlerin gelişimini izlemek mümkündür [20].

Kullanılabilirlik çalışmalarında video tabanlı göz izleme tekniği en yaygın olarak kullanılan göz izleme yöntemidir. İlk başlarda sadece laboratuvar ortamında kullanılan bu yöntem, teknolojinin hızla ilerlemesi, dolayısıyla cihaz edinme maliyetinin düşmesi ve cihazların etkinliğinin artması nedeniyle gündelik hayatta da kendine yer edinmiştir. Göz izleme birimi başa takılarak veya kullanıcının karşısına yerleştirilerek (insan-bilgisayar etkileşimi araştırmalarında genellikle ekranın alt kenarına iliştirilerek) kayıt yapar. Birimin bileşenlerinden olan kamera ve gerekli yazılım ile göz hareketleri ve bakışlar izlenerek daha sonra analiz edilmek üzere bilgisayara kaydedilir. [21]

Göz izleme yönteminde ölçülen değişkenler:

- *Fiksasyon bilgisi*, bireylerin uyaranlara verdikleri dikkati ölçmek için kullanılabilir [22].
    - *Fiksasyon süresi:* Bilgiye odaklanma süresini verir, 300 milisaniyeden daha uzun odaklanmalardır [23]. Beynin gözden gelen bilgileri işlemesini içerir. [24] Uzun süreli odaklanma objenin ilginç olarak algılandığını gösterirken, aşırı uzun süreli odaklanma bilginin beyin tarafından işlenmesi ve

yorumlanmasında zorluğu gösterir. Artarda yapılan odaklanmalar ise verimsiz görsel aramanın göstergesidir [25].
  - *Fiksasyon sayısı:* Kullanıcının objeye kaç defa odaklandığını gösterir.
- *Sakadlar:* Gözün fiksasyonlar arasında dikkati bir hedeften diğerine kaydırması nedeniyle hızlı hareket etmesidir [24]. Sakadlar kritik bir bilişsel olay meydana geldiğinde başlar ve bir dikkat kaymasını temsil eder [26]. Bu hareket vücudun üretebileceği en hızlı harekettir ve genellikle tamamlanması 30-80 milisaniye sürer [27].
- *Göz bebeği çapı:* Pupil çapı 1,5 mm – 8mm arasında değişebilir. Görevin zorluğu arttıkça göz bebeği çapı da artar.
- *Göz kırpma sayısı:* Bilişsel yük arttıkça göz kırpma sayısı azalır.

Göz izleme araştırmaları sonucunda elde edilen veriler, piyasada bulunan yazılım paketleri kullanılarak analiz edilebilir, sentezlenebilir ve kullanıcıların arayüzlerdeki hangi alanlara dikkatlerinin yoğunlaştığının tespit edilmesini sağlayan [28] ısı haritaları (heat maps) ve bakış grafikleri (gaze plots) gibi farklı görsel veriler elde edilebilir [29]. Isı haritaları (heat maps) bir arayüz üzerinde gözlenen ve gözlenmeyen alanları farklı renklerde görselleştirir [30]. Gaze plot ise bir bakış örüntüsünde sakadların ve fiksasyonların sırasını gösteren bir bakış grafiğidir [31].

3 Göz izleme yöntemiyle yapılan kullanılabilirlik çalışmaları

Wang ve arkadaşları [32] göz izleme yöntemiyle web sitesi karmaşıklığının kullanıcıların davranışları üzerindeki etkilerinde farklılıklar olup olmadığını araştırdılar. 42 katılımcıyla yapılan araştırmada kullanıcılara görevler vererek web sitesine bakış sürelerinden ısı haritası oluşturuldu. Bu şekilde kullanıcıların ne kadar süre hangi web sitesi bölümlerine baktıklarının verileri elde edilerek web sitesinin bilgi içeriğine göre odaklanma süresinin olduğu ortaya çıkarıldı.

Barkana ve arkadaşları [33] böbrek tümörü ameliyatı için kullanılmak üzere tasarlanan bir cerrahi arayüzü göz izleme yöntemiyle geliştirmeyi hedeflemişlerdir. Cerrahi arayüz kullanılırken kullanıcıların arayüzün bilgilendirici bölgelerine odaklanma sayısı ve süresi analiz edilmiş ve elde edilen veriler cerrahi arayüzü geliştirmek için kullanılmıştır.
Elektronik Sağlık Kayıtları (ESK) kullanıcı arayüzlerinin de bilişsel iş yükü ve performans ilişkisini incelendiği bir çalışmada farklı yöntemlerle birlikte bilişsel yükü tahminlemede göz izleme teknolojisini kullanılmıştır [34].

Sonuç

Sağlık bilgi sistemlerinin kullanımı kolay, kullanıcı bilgi ihtiyaçlarını karşılaması ve güvenli olması çok önemlidir. Ancak, şu anda sağlık bilgi sistemleriyle ilgili çok çeşitli kullanılabilirlik problemleri bulunmaktadır. İnsan bilişsel süreçlerini ölçmek için

kullanılan göz izleme teknolojisi, sağlık bilgi teknolojilerinin kullanılabilirlik çalışmalarında önemli bir potansiyeline sahiptir.

Kaynakça

1. J. R. Y. S. H. B. D. H. S. &. C. T. Preece, Human-computer interaction. .., Addison-Wesley Longman Ltd, 1994.
2. R. Y. S. H. Preece J, Interaction design: beyond human–computer interaction, New York: Wiley, 2002.
3. J. Nielsen, «Usability 101: Introduction to Usability,» 04 Ocak 2012. [Çevrimiçi]. Available: https://www.nngroup.com/articles/usability-101-introduction-to-usability/. [Erişildi: 26 Temmuz 2019].
4. M. B. E. M. K. A. W. &. A. S. Househ, «mHealth: a passing fad or here to stay? In Telemedicine and e-health services, policies, and applications: Advancements and developments,» *IGI Global,* pp. 151-178, 2012.
5. J. H. &. W. D. D. Obradovich, «Users as designers: how people cope with poor HCI design in computer-based medical devices,» *Human factors,* cilt 38, no. 4, pp. 574-592, 1996.
6. A. W. T. M. M. B. E. M. S. B. &. K. J. L. Kushniruk, «Technology induced error and usability: the relationship between usability problems and prescription errors when using a handheld application.,» *International journal of medical informatics,* cilt 74, no. 7-8, pp. 519-526, 2005.
7. T. Baylis, Low-cost rapid usability testing for health information systems: is it worth the effort? (Doctoral dissertation), 2011.
8. E. M. H. F. M. S. K. A. W. N. C. &. T. H. Borycki, «Empowering patients: making health information and systems safer for patients and the public,» *Yearbook of medical informatics,* cilt 21, no. 01, pp. 56-64, 2012.
9. R. W. T. T. J. L. &. K. B. T. Koppel, «Workarounds to barcode medication administration systems: their occurrences, causes, and threats to patient safety,» *Journal of the American Medical Informatics Association,* cilt 15, no. 4, pp. 408-423, 2008.
10. V. &. K. A. Patel, «Interface design for health care environments: The role of cognitive science,» %1 içinde *In C. Chute (Ed.) Proceedings of the AMIA 98 Annual Symposium*, 1998.
11. N. J. T. B. W. &. H. D. Wade, «Dodge-Ing the Issue: Dodge, Javal, Hering, and the Measurement of Saccades in Eye-Movement Research.,» *Perception,* cilt 32, no. 7, p. 793–804, 2003.
12. R. J. &. K. K. S. Jacob, «Eye tracking in human-computer interaction and usability research: Ready to deliver the promises,» 2003, pp. 573-605.

13. O. &. Y. Y. Asan, «Using eye trackers for usability evaluation of health information technology: a systematic literature review,» *JMIR human factors,* cilt 2, no. 1, p. e5, 2015.
14. C. D. H. J. G. B. S. &. P. R. Wickens, Engineering psychology and human performance., Boston, MA: Pearson;, 2012.
15. G. K. Poock, «Information processing vs pupil diameter.,» *Perceptual and Motor Skills,* cilt 37, no. 3, pp. 1000-1002, 1973.
16. O. K. A. L. S. A. &. H. P. Palinko, «Estimating cognitive load using remote eye tracking in a driving simulator,» *In Proceedings of the 2010 symposium on eye-tracking research & applications,* p. 141–144., 2010.
17. D. C. &. S. M. J. Richardson, «Eye tracking: Research areas and applications,» *Encyclopedia of biomaterials and biomedical engineering,* pp. 573-582, 2004.
18. M. G. &. R. E. M. Glaholt, «Eye movement monitoring as a process tracing methodology in decision making research,» *Journal of Neuroscience, Psychology, and Economics,* cilt 4, no. 2, p. 125, 2011.
19. W. &. K. P. Einhäuser, «Getting real-sensory processing of natural stimuli,» *Current Opinion in Neurobiology,* cilt 20, no. 3, p. 389–395, 2010.
20. P. W. N. K. T. C. O. J. P. O. S. E. B. V. .. &. K. K. König, «Eye movements as a window to cognitive processes,» *J. Eye Mov.,* cilt 9, no. 5, pp. 1-16, 2016.
21. P. &. B. A. Majaranta, «Eye tracking and eye-based human–computer interaction,» *In Advances in physiological computing,* pp. 39-65, 2014.
22. R. &. D. Y. Vertegaal, «Explaining effects of eye gaze on mediated group conversations: amount or synchronization?,» %1 içinde *In Proceedings of the 2002 ACM conference on Computer supported cooperative work*, 2002.
23. S. T. T. H. J. M. E. O. K. &. B. J. Djamasbi, «Gender preferences in web design: usability testing through eye tracking,» *AMCIS 2007 Proceedings,* p. 133, 2007.
24. B. L. Poole A, «Eye tracking in human-computer interaction and usability research: Current status and future. In: Ghaoui C, editor. Encyclopedia of Human-Computer Interaction,» *Hershey, PA: Idea Group Reference,* p. 211–219, 2005.
25. J. H. &. K. X. P. Goldberg, «Computer interface evaluation using eye movements: methods and constructs,» *International Journal of Industrial Ergonomics,* cilt 24, no. 6, pp. 631-645, 1999.
26. G. W. &. Y. S. N. McConkie, «How cognition affects eye movements during reading,» *In The Mind's Eye,* pp. 413-427, 2003.
27. J. P. U. &. R. H. Zagermann, «Measuring cognitive load using eye tracking technology in visual computing,» %1 içinde *In Proceedings of the sixth workshop on beyond time and errors on novel evaluation methods for visualization*, 2016.

28. S. S. M. &. T. T. Djamasbi, «Generation Y, web design, and eye tracking,» *International journal of human-computer studies,* cilt 68, no. 5, pp. 307-323, 2010.
29. J. &. P. K. Nielsen, Eyetracking web usability, New Riders, 2010.
30. O. &. M. D. Špakov, «Visualization of eye gaze data using heat maps,» *Elektronika ir elektrotechnika,* pp. 55-58, 2007.
31. S. &. L. K. Shrestha, «Eye gaze patterns while searching vs. browsing a Website,» *Usability News,* cilt 9, no. 1, pp. 1-9, 2007.
32. Q. Y. S. L. M. C. Z. &. M. Q. Wang, «An eye-tracking study of website complexity from cognitive load perspective,» *Decision support systems,* pp. 1-10, 2014.
33. D. E. &. A. A. Barkana, «Improvement of design of a surgical interface using an eye tracking device,» *Theoretical Biology and Medical Modelling,* cilt 11, no. 1, p. S4, 2014.
34. L. M. M. P. R. M. C. &. M. L. Mazur, «Association of the Usability of Electronic Health Records With Cognitive Workload and Performance Levels Among Physicians,» *JAMA network open,* cilt 2, no. 4, 2019.

YOĞUN BAKIM BİLGİ YÖNETİM SİSTEMLERİNİN SAĞLAMASI GEREKEN TEMEL ÖZELLİKLER

Gözde Ünal[1], Filiz İşleyen[1], Esra Muş[1]

[1] T.C. Sağlık Bakanlığı, Sağlık Bilgi Sistemleri Genel Müdürlüğü, Ankara, Türkiye.
gozde.unal2@saglik.gov.tr

Abstract.

Clinical information systems are used in order to help managing daily big data generated in hospitals. Clinical information system used in intensive care units (ICU) is YBBYS (Clinical information systems in the intensive care unit). YBBYS is a system which works integrated with medical devices used in ICU and other clinical information management systems.YBBYS also has features like early warning, clinical decision support systems. The aim of our study is to determine the minimum criteria which YBBYS has to provide and present user opinions. Therefore research has been done in clinical facilities. Present YBBYS criterias analysed in health facilites which are evaluated together with the literature search. The minimum features which are thought to be mandotary are documented. Quantitative research methods are used in this study. User feedback and YBYYS features are evaluated in conjunction. minimum criteria is defined with minimum descriptive analysis. As a result, the criteria specified in our country's health facilities to improve the quality of health care provided in ICUs, reduce the workload of health care workers, minimize employee-related errors, reduce documentation and so on For the benefits of any YBBYS is considered to be the minimum required features.

Keywords: İntensive Care Unit, Clinical information systems in the intensive care unit, Clinical information systems.

Özet.

Hastanelerde her gün üretilen büyük miktarda tıbbi verinin yönetilmesine yardımcı olmak için klinik bilgi sistemleri kullanılmaktadır. Yoğun bakım ünitelerinde (YBÜ) kullanılan klinik bilgi sistemlerine Yoğun Bakım Bilgi Yönetim Sistemi (YBBYS) denilmektedir. YBBYS, YBÜ'lerde kullanılan tıbbi cihaz ve diğer Sağlık Bilgi Yönetim Sistemleri (SBYS) ile entegre çalışan, erken uyarı ve Klinik Karar Destek Sistemleri (KKDS) gibi özellikleri bulunduran bir sistemdir. Çalışmamızın amacı, ülkemizde kullanılan YBBYS'lerin sağlaması gereken asgari kriterlerin belirlenmesi ile kullanıcı görüşlerinin sunulmasıdır. Bu amaçla YBBYS kullanan bazı sağlık tesislerinde incelemeler yapılmıştır. Çalışmada nitel araştırma yöntemleri kullanılmıştır. Kullanıcı görüşleri ve YBBYS'lerde bulunan

özellikler birlikte değerlendirilerek betimsel analiz yöntemi ile asgari kriterler belirlenmiştir. Sonuç olarak tespit edilen kriterlerin, ülkemiz sağlık tesislerindeki YBÜ'lerde sunulan sağlık hizmeti kalitesini artırmak, sağlık çalışanlarının iş yükünü azaltmak, çalışan kaynaklı hataları en aza indirmek, dokümantasyonu azaltmak vb. faydalar için herhangi bir YBBYS'nin sağlaması gereken asgari özellikler olduğu düşünülmektedir.

Anahtar Kelimeler: Yoğun Bakım Ünitesi, Yoğun Bakım Bilgi Yönetim Sistemi, Sağlık Bilgi Yönetim Sistemi.

1 Giriş

Hastanelerde her gün üretilen büyük miktarda verinin yönetilmesine yardımcı olmak için klinik bilgi sistemleri kullanılmaktadır. Yoğun bakım ünitelerinde (YBÜ) kullanılan klinik bilgi sistemlerine Yoğun Bakım Bilgi Yönetim Sistemi (YBBYS) denilmektedir. YBBYS, YBÜ'lerdeki süreçleri bilgi teknolojileri aracılığı ile iyileştirmek amacı ile geliştirilmiş, sağlık personeline yardımcı bilgiler sunan bir sağlık yazılımıdır.

Sağlık hizmeti sunumunun etkinliğinin ve hızının artırılabilmesi için YBBYS ile, hastaya ait tüm klinik bilgilere (vital bulgular, kan gazı sonuçları, laboratuvar sonuçları, radyoloji raporları, ventilatör değerleri vb.) hızlı bir şekilde 7x24 ulaşılabilmeli, hastanın mevcut klinik durumu ile ilgili bilgiler sağlık personeline anlık olarak iletilebilmelidir. YBBYS'nin, Hastane Bilgi Yönetim Sistemi (HBYS), Laboratuvar Bilgi Yönetim Sistemi (LBYS), Radyolojik görüntüleme (PACS/RIS) vb. hastanedeki diğer Sağlık Bilgi Yönetim Sistemleri (SBYS) ile tam entegre çalışabilmesi ile bu sistemlerden elde edilen ve yoğun bakım sürecinde kullanılması gereken tüm veriler, YBBYS üzerinde de görülebilmektedir.

YBBYS, ventilatörler, hasta başı monitörleri, kan gazı cihazları vb. cihazlara, mobil cihazlarla uzaktan erişim sağlayarak, gerektiğinde mod ayarlarını güncelleyebilmesi, uluslararası standartlarca kabul görmüş yoğun bakım skorlamalarını (Mortalite, GKS, Apache, SAPS vb.) hızlı bir şekilde yapabilmesi, Sepsis ve Septik Şok için uyarıların yapabilmesi gibi faydalar sağlamaktadır.

Erken uyarı bildirim yöntemlerinin YBBYS'de kullanılması, hasta bakım ve tedavisinin doğru zamanda, doğru şekilde uygulandığını kontrol etme imkanı sağlamaktadır. Tıbbi verilerin merkezi bir veri tabanında toplanması, işlenmesi ve kullanıcılara verilen anlık geri bildirimler, YBÜ'lerde sağlık hizmetinin kalitesini arttırmakta ve hasta bilgilerinin kağıt tabanlı formlara değil bilgisayar ortamına kayıt edilebilmesi ile de süreçlerin yönetimini kolaylaştırmaktadır [1].

Yapılan çalışmalar, YBBYS'nin, yoğun bakım süreçlerini iyileştirme potansiyeline sahip olduğunu göstermektedir [2] ve YBÜ'de uygulanan süreçler için etkili bir çözüm olarak kabul edilmektedir [3]. Ehteshami ve ark. yaptıkları çalışmada, YBBYS'nin hastabaşı cihazları ile yapılan entegrasyon ile otomatik tıbbi veri toplamanın, elle yapılan veri girişine kıyasla zamandan tasarruf sağlaması, klinik uyarı, tanı ve tedavi süresini

azaltması, bunları optimize etme ve yaygın görülen ilaç hatalarını önlemesi gibi faydalarının bulunduğu belirtilmiştir [4].

Bu çalışmanın amacı, ülkemizde kullanılan YBBYS'lerin sağlaması gereken asgari kriterlerin belirlenmesidir.

2 Metot

Çalışma öncesinde mevcut SBYS'lerin sağlaması gereken asgari özelliklerin bulunduğu Sağlık Bakanlığı tarafından yayımlanan SBYS Alım Kılavuzu (SBYS-AK) [5] incelenerek YBBYS'lerde bulunması düşünülen kriterler belirlenmiştir.

Beş ayrı sağlık tesisi ziyaret edilerek, YBÜ'lerde kullanılan YBBYS'ler yerinde incelenmiş, önceden belirlenen kriterleri sağlama durumu raporlanmış ve kullanıcıların YBBYS'ye ilişkin görüşleri toplanmıştır.

Çalışmada nitel araştırma yöntemleri kullanılmış olup betimsel analiz ile kullanıcı görüşleri ve asgari kriterler tablolarla gösterilmiştir. Sağlık tesislerinde kullanılan YBBYS, yoğun bakım uzman hekimleri ve teknik ekip ile birlikte incelenmiştir. İnceleme sırasında, ziyaret edilen hastanelerdeki YBBYS'nin önceden belirlenen kriterleri sağlama durumu uygulamalı olarak izlenmiştir. YBBYS'lerin, yoğun bakım uzmanları ve yoğun bakım yardımcı sağlık personeli olan kullanıcılarından, sisteme ilişkin memnuniyetleri ve sistemle ilgili beklentileri ile geleneksel sistemden YBBYS'ye geçiş sürecinde karşılaştıkları zorluklar hakkında görüşleri alınmıştır.

3 Bulgular

Ziyaret edilen sağlık tesislerindeki yoğun bakım hekimleri ve yardımcı sağlık personelinden YBBYS ile ilgili görüşleri toplanmıştır. Toplanılan görüşler nitel değerlendirme yöntemleriyle analiz edilerek en sık bildirilen görüşler Tablo 1'de verilmiştir.

Tablo 1. YBBYS İçin Kullanıcı Görüşleri

YBBYS Kullanıcı Görüşleri
YBÜ'lerde bulunan tıbbi cihazlardan anlık veri alınabilmesi süreçlerde kolaylık sağlar.
Sağlıkta Kalite Standartlarının (SKS) YBBYS'de tanımlanmış olması, sistemin beklenen standarda uygun veri oluşturmasını sağlar.
YBBYS çalışanların günlük işlerinde kolaylık ve zaman tasarrufu sağlar.
Hemşire izlem kağıtlarının (Çarşaf) sistemde oluşturulması veya çıktı olarak alınabilmesi zamandan tasarruf sağlar.
Tıbbi cihaz entegrasyonları ile veri girişlerinin elektronik olması, manuel veri girişi ile yapılabilecek hata oranını azaltır.

Hastaların vital değerlerinin tek bir ekrandan ikonlarla izlenebilmesi süreçte kolaylık sağlar.
Görsel ve işitsel konsültasyon imkanı ile zamandan tasarruf sağlar.
Ortalama yatış süresinin anlık olarak izlenebilmesi, planlamalarda kolaylık, zamandan ve maliyetten tasarruf sağlar.
YBBYS'de incelenmek istenen her bir tıbbi parametrenin trendinin olması, tıbbi kararlara destek sağlar.
YBÜ hastalarında otomatik basamak hesabı yapılabilmesi, tıbbi kararlara destek sağlar.
YBBYS'lerde KKDS'lerin kullanımı, kullanıcı farkındalığının artmasını sağlar.

YBBYS'lerin, önceden belirlenen kriterleri sağlama durumu Tablo 2'de verilmiştir. İncelenen bütün YBBYS'lerin sağladığı kriterler * ile işaretlenmiş olup bu kriterlerin yeni geliştirilecek tüm YBBYS'lerde asgari olarak bulunması gereken kriterler olabileceği düşünülmüştür. Buna ek olarak incelenen YBBYS'lerin tamamında olmasa da bir kısmında bulunan ancak literatür çalışmalarında YBBYS'lerin sağlaması gereken kriterler olarak belirtilen ve asgari olarak sağlanması gereken özelliklerden olduğu düşünülen kriterler ** ile işaretlenmiştir.

Tablo 2. YBBYS'lerde İncelenen Kriterler

NO	Yoğun Bakım Bilgi Yönetim Sistemi (YBBYS) Kriterleri
1	* YBBYS KTS'de kayıtlı mı?
2	* Ventilatör Cihazı Entegrasyonu
3	** Kangazı Cihazı Entegrasyonu
4	* Hastabaşı Monitörü Entegrasyonu
5	* Vital Bulgularının Sonuç Ekranında Görülmesi
6	* Ventilatör Değerlerinin Sonuç Ekranında Görülmesi
7	* Laboratuvar Değerlerinin Sonuç Ekranında Görülmesi
8	* Kangazı Değerlerinin Sonuç Ekranında Görülmesi
9	** Radyoloji Değerlerinin Sonuç Ekranında Görülmesi
10	* Hastanın klinik durumu ile ilgili anlık bilgi alarak tedaviye uzaktan müdahale edilebilmesi
11	* Hasta tedavisinin doğru uygulandığının kontrolüne ilişkin ara yüzler bulundurması
12	* Erken Uyarı Sistemi
13	** Klinik Karar Destek Sistemleri (KKDS)
14	** Ventilatörler, hastabaşı monitörleri, kangazı cihazları vb. cihazlara, mobil cihalarla uzaktan erişim sağlanması
15	** Sepsis ve Septik Şok için uyarı ekranları

16	* Otomatik GKS (Gloskow Koma Skalası) Hesabı
17	* Otomatik Apache Hesabı
18	* Talep Halinde Diğer Skorlamaların Eklenmesi Durumu
19	** Hastanın klinik durumu ve hekim notu ile birlikte 1. Basamak, 2. Basamak ya da 3. Basamak şeklinde otomatik basamak hesabı yapılabilmesi
20	* Hastanın ortalama yatış süresinin izlenebilmesi
21	* Hastaya ait parametrelerin (vital bulgular, kangazı, radyoloji ve laboratuvar sonuları, ventilatör değerleri vb.) tek bir ekranda gözlenebilmesi
22	** Hemşire gözlem raporunun (çarşaf) çıktı olarak alınması
23	** Sağlıkta Kalite Standartlarında (SKS) belirtilen hemşire takip formlarının sistemde Bulunması
24	* Tıbbi parametler için trendlerin bulunması
25	** Ana ekrandan boş yatak bilgisinin izlenmesi
26	** LBYS Entegrasyonu
27	** PACS Entegrasyonu
28	* HBYS Entegrasyonu
29	* Yoğun Bakım Verilerine İlişkin Raporlama
30	* Kullanılan sistemin Türkçe olması

4 Tartışma ve Sonuç

YBBYS, verinin anlık takibi, veriye uzaktan erişim imkanı, erken uyarı ve klinik karara destek sağlayan özellikleri ile mortaliteyi azaltmakta, personel kaynaklı oluşabilecek hataları minimize ederken, sunulan sağlık hizmeti kalitesini maksimize etmektedir. Ancak kullanıcıların YBBYS'yi sahiplenmediği durumlarda, geliştirilen sistemin son teknoloji araçları ile tasarlanmış ya da çok iyi planlanmış olması sistemin başarısı için yeterli olmayacağı düşünülmektedir. Yaptığımız çalışmada, kullanıcılardan geleneksel sistemden YBBYS'ye geçiş sürecinde, tıbbi cihazların YBBYS'ye entegrasyonunda sorun yaşanması, maliyet gerektirmesi sebebiyle olan çekimserlik, kullanıcıların değişikliğe olan direnci gibi zorluklar yaşandığı ancak sistemin kurulumu sonrasında yüksek memnuniyet sağladığı gibi bilgiler alınmıştır. Çalışmanın yapıldığı dönem YBBYS'lerin en az bir yıl kullanımı sonrasına karşılık gelmektedir. Bu nedenle çalışmamızda, kullanıcıların Tablo 1'de memnuniyet içeren görüş sayısı fazladır. Tüm kullanıcılar sistemlerin kullanımını iş süreçlerine tamamen taşımış olduğu için geçiş sürecinde yaşanılan sorunları çalışma sürecinde sorun olarak nitelendirmemişlerdir.

YBÜ koşulları, açıkça veri toplama ve yönetim görevlerinin uygulanmasını zorlaştırır. Klinik ihtiyaçların değerlendirilmesi, hastanın durumuna ve yatak başında mevcut olan koşullara bağlı olarak değişebilir. Hasta durumundaki değişiklikler kaçınılmaz olarak, kağıt ve elektronik kayıtlar yoluyla başucunda toplanan verilerin miktarını artırır [6]. YBBYS'lerde tıbbi cihazlardan toplanan verilerin analizi ile raporlanması sağlık personelinin hastanın tedavisine ilişkin vereceği kararlara destek oluşturabilir. Nitekim

kullanıcılar, YBBYS'de incelenmek istenen her bir tıbbi parametrenin trendinin olmasının verdikleri tıbbi kararlara destek sağladığına ilişkin görüş bildirmişlerdir.

Bu çalışmada, Sağlık Bakanlığı tarafından geliştirilen SBYS-AK temel alınarak YBBYS'lerde bulunması düşünülen kriterlerin, ülkemizde beş hastanede kullanılan beş farklı YBBYS'de bulunma durumları incelenmiştir. İnceleme sonucunda beş farklı YBBYS'nin tamamının veya çoğunluğunun sağladığı kriterlerin ülkemizde kullanılacak tüm YBBYS'lerin sağlaması gereken asgari kriterler olması gerektiği düşünülmüştür. Buna ek olarak incelenen YBBYS'lerin çoğunluğunun sağlamadığı ve Tablo.2'de ** ile belirtilen kriterler ise literatür çalışmaları göz önünde bulundurularak seçilen kriterleri ifade etmektedir. Bu kapsamda, YBBYS'lerin sağlaması gereken asgari özellikler olarak seçilen kriterler Tablo 2'de * ve ** işaretleri ile sunulmuştur. Tablo.1'de bulunan "YBBYS'lerde KKDS'lerin kullanımı, kullanıcı farkındalığının artmasını sağlar." kullanıcı görüşü de Tablo.2'de bulunan "** Klinik Karar Destek Sistemleri (KKDS)" kriterinin asgari kriterlerden olarak seçilmesini destekleyici bir unsur olarak sayılabilir.

Sonuç olarak Tablo 2'de *ve ** işaretleri ile belirlenen kriterlerin, ülkemizdeki YBÜ'lerde sunulan sağlık hizmeti kalitesini artırmak, sağlık çalışanlarının iş yükünü azaltmak, çalışan kaynaklı hataları en aza indirmek ve kullanıcı memnuniyetini arttırmak için herhangi bir YBBYS'nin sağlaması gereken asgari özellikler olduğu düşünülmektedir. Çalışmamızda, tespit edilen asgari kriterler, incelenen sağlık tesisi ve YBBYS sayısı arttırılarak kullanıcı talepleri veya sağlık tesisi alt yapısına göre genişletilebilir.

Başvurular

[1] Plenderleith, J.L., «Clinical information systems in the intensive care unit,» *Anaesthesia And İntensive Care Medicine,* cilt 14, no. 1, pp. 19-21, 2013.

[2] Berger, M.M, Revelly, J.P, Wasserfallen, J.B, Schmid, A., Bouvry, S., Cayeux, M.C., Musset, M., Maravic, P., Chiolero, R.L., «Impact of a computerized information system on quality of nutritional support in the ICU,» *Nutrition,* cilt 22, no. 3, pp. 221-229, 2006.

[3] Hristoskova, A., Moeyersoon, D., Hoecke, S.V., Verstichel, S., Decruyenaere, J., Turck, F., «Dynamic composition of medical support services in the ICU: Platform and algorithm design details,» *Computer Methods and Programs in Biomedicine,* cilt 100, no. 3, pp. 248-264, 2010.

[4] Ehteshami, A., Sadoughi, F., Ahmadi, M., Kashefi, P., «Intensive Care Information System Impacts,» *PMC,* cilt 21, no. 3, pp. 185-191, 2013.

[5] Sağlık Bakanlığı, «Sağlık Bilgi Yönetim Sistemi Alım Kılavuzu,» Ankara, 2019.

[6] Subías, P., Ribas, V., «Big Data for Critical Care,» 2018.

KLİNİK ARAŞTIRMALARDA BİLGİ SİSTEMLERİ: NİTEL BİR İHTİYAÇ ANALİZİ

Göksu Bozdereli Berikol[1], Neşe Zayim [2]

[1] Bakırköy Dr Sadi Konuk Eğitim ve Araştırma Hastanesi, Acil Tıp Kliniği, İstanbul, Türkiye
[2] Akdeniz Üniversitesi Tıp Fakültesi, Biyoistatistik ve Tıp Bilişimi A.D, Antalya, Türkiye
gokxsu@hotmail.com

Abstract. Cases that are important for the literature encountered in daily practice in polyclinics, emergency services and intensive care units are recorded by clinicians and presented to large audiences in medical literature. Particularly because of the emergency service crowd, problems related to ethical issues, speed, pressure and urgency, there are problems with the collection of research data. In this study, we investigated the suggestions of health personnel in various branches to analyze the needs of the application to be developed for data collection for scientific researches and suggestions about a system design that could be developed. Finally it is concluded that the new system needs to be developed, practical, accessible, storable, integrable, intelligent and durable.

Keywords: Data collection, scientific research, qualitative analysis

Özet

Poliklinik, acil servis, yoğun bakım gibi birimlerde günlük pratikte karşılaşılan literatür için önem arz eden vakalar klinisyenler tarafından kaydedilip, ilgili alanlarda geniş kitlelere sunulmaktadır. Özellikle acil servis yoğunluğu, etik konularla ilgili problemler, hız, baskı, ivedilik içerdiğinden araştırma verileriin toplanması ile ilgili sorunlar yaşanmaktadır. Çalışmamızda çeşitli branşlarda sağlık personelinin bilimsel araştırmalar için veri toplamasına yönelik geliştirilecek uygulama için ihtiyaçlarının analizini yapmak, geliştirilebilecek bir sistem tasarımı hakkındaki önerileri araştırılmıştır. Dolayısı ile yeni sistemin kullanılabilir, pratik, ulaşılabilir, depolanabilir, entegre edilebilir, akıllı ve süreklilik arz eden bir sistem geliştirilmesi gerektği bunları yaparken güvenlik ve mahremiyet sorunlarının da göz önünde bulundurulması gerektiği sonucuna varılmıştır

Anahtar Kelimeler: Bilimsel araştırma, nitel analiz, veri toplama

1 GİRİŞ

Klinik araştırma olan deneysel çalışmalar, özgün araştırmalar, vaka serileri, vaka sunumları tıp literatürüne büyük katkı sağlamaktadır. Poliklinik, acil servis, yoğun bakım gibi birimlerde günlük pratikte karşılaşılan literatür için önem arz eden vakalar klinisyenler tarafından kaydedilip, ilgili alanlarda geniş kitlelere sunulmaktadır. Özellikle acil servis etik konularla ilgili problemler, hız, baskı, ivedilik içerdiğinden araştırmalar kesintilere uğramaktadır(1). Özellikle acil servis, poliklinikler gibi sirkülasyonunun çok yoğun olduğu yerlerde önem arz eden hastalarla ilgili zaman kısıtı, hasta yoğunluğundan dolayı unutma, verilerin zamanında toplanamaması, verilerin tek yerde toplanamaması, akut durumda verinin elde edilememesi, onam almada gecikme gibi nedenlerden dolayı önemli vakalar yoğunluk nedeni ile kaçırılmakta, sonradan hatırlanmada zorluk yaşanmakta, ya da onam alma sırasında güçlük yaşanmakta, kayıt tutulabilse bile bazı tetkik ve görüntülerin manuel kaydedilmesinde zorluk yaşanabilmektedir. Bu durum da olduğundan daha az vakanın literatüre geçmesine yol açmaktadır. Bu zorlukların giderilmesinde bilgi sistemlerinin katkısından bahsedilebilir. Bilgi sisteminin özellikle bilimsel araştırmalara yönelik veri toplamaya nasıl katkı sağlayabileceği, klinisyenlerin karşılaştığı sorunlara nasıl cevap verebileceği hakkında sağlık personelinin bu konudaki görüşlerine ihtiyaç duyulmaktadır.

Bu çalışmanın amacı sağlık bakım sürecinde bilimsel araştırmalar için veri toplamasına yönelik geliştirilecek uygulama için ihtiyaçlarının analizini yapmaktır. Bu amaca yönelik, bilimsel araştırma amaçlı kayıt tutma sürecini ve süreçte karşılaştıkları sorunları ve geliştirilebilecek bir sistem tasarımı hakkındaki önerilerini belirlemektir.

1.1 Araştırma amaçlı veri toplama sürecini etkileyen faktörler

Klinik araştırmalar için veri kaydetme ve veri toplama

Bilimsel klinik araştırmaların geçerliliği, hasta bakım pratiği süresince verinin doğru ve tam girilme başarısına bağlıdır. Özellikle bunlar için gönüllü araştırmacılar hasta başvurusu sırasında ya da takibinde bulunmaması halinde, pratikte tam yakalanamayan projeler başarı gösterememektedir (2). Özellikle acil servislerde, epidemiyolojik çalışmalarda var olan veri önem kazanmaktadır (3). Veri kaydı hasta bakımı için yapılmakta, veri kâğıda ya da bilgi sistemine aktarılırken bilimsel araştırma amacı güdülmemektedir. Oysa başta retrospektif çalışmalar olmak üzere bilimsel araştırmalar için veri eksik, uygunsuz, kayıplı olmamalıdır (4).

Pratikte kliniklerde veri toplama sorunları.

Acil servis gibi hasta yoğun polikliniklerde hastaların bakısı ve bakımına ayrılan süre kısıtlı olabilmektedir. Zaman organizasyonu tanı ve tedaviye yoğunlaştığından bilimsel araştırmalara yön gösterecek özellikli hastaların ya da çalışmalara veri toplanmasına ayrılan süre de bu durumla ilişkili olmaktadır.

Bilgi özellikle acil servislerde, ambulans şöförü, hasta yakını, olaya şahit olmuş bir tanık vb gibi. bir çok yerden toplanmaktadır. Ayrıca yoğun bakımda yatan bir epilepsi hastasının jeneralize tonik klonik nöbetini kayda almak da hastane bilgi sistemi ile mümkün olamamaktadır. Literatüre kazandırılabilecek hastaların o andaki durumları, lezyonları, ya da bir çalışmaya ait bir hastanın olduğunun farkına varıldığı an hastanın operasyona alınması, başka merkezlere sevk edilmesi gibi durumların sonucunda veri de kaybedilmektedir.

Veri Kalitesi

Verilerin kalitesi doğruluk, güvenilirlik, önem, tutarlılık, hassaslık, zamanlamalılık, incelik, anlaşılırlık, özlü ve kullanışlılığı içermektedir. Verilerin kalitesinin verilerin nasıl kullanılacağına bağlı olduğu da ileri sürülmüştür. Verinin kullanım amacını yerine getirmek için hangi veri alanlarının kullanıldığı olarak tanımlanabilir. Acil servis veri toplama süreçlerini araştırmak için uygun veri kalitesi CIHI 2009'da yer alan dört temel boyutu olan doğruluk, geçerlilik süresi, karşılaştırılabilirlik ve klinik verilerin kullanılabilirliğine bağlıdır. Acil servis veri tabanlarının ve kayıt defterlerinin bilimsel araştırma ihtiyacını karşılaması ile ilgili çalışmalar mevcuttur (5).

Araştırma bilgi sisteminin özellikleri

Pratikte araştırma bilgi sisteminin istenen özellikleri farklı veri tiplerini toplayabilmesi, çalışmaya hastaları episodları kaydedebilmesi, düzenli ve özellikli sorgulamaları desteklemesi, verileri olduğu gibi kaydedebilmesi, bölgeler arası iletişim varsa bölgelerarası data kaydedebilmelidir. Pratikteki gibi aynı veritabanını kullanan bir sistemde veri bir sistemden diğerine transfer edilebilmektedir(2)

Etik Konular

Bununla birlikte etik konulara da bilimsel araştırma sürecinde önem verilmelidir. Özellikle hasta bakımı sırasında sağlık vericilerin aklına bilimsel bir çalışmada rol oynayabileceği ve bilgilendirilmiş yazılı onam almak gelemeyebilmektedir(1).

Kontrol Teorisi

Bilgi sistemleri ile ilgili bir teori olup, basit negatif feedback döngüsüdür. Hedef durum, sistemin durumu ve kullanıcıların kontrol stratejileri kullanıcıların hareketlerini belirler(6). Kompleks sosyoteknik sistemlerde başlangıç durumları kesin olarak bilinmez. Kullanım gözlemlendikten sonra davranışlar ortaya çıkabilir.

Bilimsel çalışmalar için veri toplama süreçlerini etkileyen faktörler Şekil1'de özetlenmiştir.

2 MATERYAL VE METOD

Çalışmada sağlık bakm süreçlerinde araştırma amaçlı veri toplama ve kaydı ile süreçleri derinlemesine anlamak amaçlandığı için nitel araştırma yöntemi kullanılmıştır.

Sistem geliştirme çalışmalarında nicel yaklaşımlarla yapılan çalışmalar, tasarıma kullanıcıların tam olarak dahil edilememesine neden olabilmektedir (7). Oysa tasarıma kullanıcıların katılımı ile ön görülen ihtiyaçların dışında, yeni farkedilen gereksinimler ortaya çıkmakta, bu da tasarımın gerekliliklerini anlamaya fayda sağlamaktadır.
Araştırma farklı branşta, farklı yaşlarda, farklı deneyimlerdeki, farklı sağlık merkezlerinde uzman düzeyinde dört sağlık personeli ile yarı yapılandırılmış görüşme yöntemi ile gerçekleştirilmiştir. Katılımcıların onayı alınarak görüşmeler ses kayıt cihazı ile kaydedilmiş, Yaklaşık 20 dakika) süren görüşmeler sonrasında yazılı transkriptler elde edilmiştir.

Görüşmelere ait veriler görüşmelerden toplanan nitel veriler, literatürde sıklıkla "sürekli karşılaştırmalı analiz yöntemi" olarak da adlandırılan "gömülü teori" yöntemi kullanılarak ortak ve yeni ortaya çıkan temalar için analiz edilmiştir (8).

3 BULGULAR

3.1 Bilimsel Araştırma İçin Veri Toplama Sürecini Etkliyen faktörler

1. Hasta Bakım Sürecine Ait Faktörler

Tanı tedavi bazlı kayıt
. Veri kaydetme ve veri toplama kliniklerde bilimsel araştırma amacından çok hastanın tanısı ve tedavisine yönelik olmaktadır(4). Bu amaca yönelik kayıtlar özellikle bilimsel araştırma için gerekli parametrelerin yokluğunda sadece hastanın hatırlatılmasına yönelik olarak yazılmaktadır. Bir katılımcı kayıt işleminin tanı ve faturalandırma için olduğunu belirtmiştir.

"HBS var ama SGK muayene tanıları görmek ve faturalandırmak için genelde bu işlem yapılıyor. Onun dışında da herhangi bir araştırma ya da hasta takibi için malesef bilgi sistemleri kayıt sistemleri yetersiz devlet hastanelerinde."

Bakım önceliği
. Hasta muayene süreçlerindeki zorluklar, hastaların bakım önceliği endişeleri gibi nedenlerle veri kaydına verilen önemin azalmakta olduğu, dolayısı ile muayene ve verinin kalitesinde düşüklük gözlemlendiği kaydedildi. Özellikle hasta yoğunluğu yüksek poliklinikler gibi yerlerde, bekleme sürelerini aşmamak adına katılımcılarca veri kaydının istenilen düzeyde olmadığı belirtilmiştir.

"Çok zor, günde 150 hasta bakıyorum. 6 saatlik bir zaman diliminde hepsine bakmak zorundayım. Bu şekilde kalitesi düşük bir muayene süreci geçiriyorum."

"Bütün kliniğe günde doktor basına düşen hasta sayısı asgari 60 80 randevulu hasta bazen 100 110 120 bazen 150 ye kadar çıkabilir. Hastalara isimlerini bile sorsanız bu sürenin yetmeyeceği aşikardır."

Zamansal Faktörler

Hasta bakım sürecinin kendisnin hali hazırda zor olmasının yanında, hasta yoğunluğuna bağlı olarak bakım kalitesinin düşüklüğü de veri toplama sürecini olumsuz yönde etkilediği düşünülmektedir. Katılımcılar hasta muayene süreçlerindeki hasta yoğunluğundan kaynaklı zaman kısıtı nedeniyle, hastanın bütüncül değerlendirilme olanağı olmadığı, dolayısı ile hem bakım kalitesi için süreçte toplanan anamnez/fizik muayene verilerinin yetersiz olduğunu bildirmişlerdir.

"Zamanımız kısıtlı olduğu için en çok şikayeti hangi bölgede ise hangi şikayeti varsa ona yönelik tetkiklerini istiyoruzFazla fizik muayene bulgusu sadece şikayeti olan bölgeyi tarıyoruz. Genel olarka bir norolojik muyene yapmak gibi bir şansımız ve zamanımız malesef yok poliklinikte "

"Çok zor, günde 150 hasta bakıyorum. 6 saatlik bir zaman diliminde hepsine bakmak zorundayım. Bu şekilde kalitesi düşük bir muayene süreci geçiriyorum."

"Genelde devlet hastanelerinde çok kısa olduğu]için değerlendirmenin tam olarak yapıldığı söylenemez"

Bunların yanı sıra hastaneler arası hasta çeşitliliğinin değişkenliği, hasta yakınlarından kaliteli onam alma sürecinin zorluğu ve bakım sürecine dahil olan uzmanların deneyimlerinin değişkenliği de bakım süreci ile birlikte toplanacak verileri ve kalitesini de etkilemekte olduğu düşünülmüştür

Hasta bakımı ve veri kaydını etkileyen önemli bir faktörün zaman kısıtlılığı olduğu her 3 katılımcı tarafından da belirtilmiştir. Zaman hem hasta bakımı, veri girişi gibi durumları etkilemekte olduğu tüm katılımcılarca ele alınmıştır. HBSnin kullanışsız olması, hasta sayısının çok olması, girilmek istenen parametrelerin çok olması gibi durumlar nedeni ile katılımcılar zaman kaybetmemek nedeni ile veri girişini ön plana almadığı görülmektedir.

"Hasta geldiğinde direk ilk olarak şikayetini soruyoruz, Zamanımız kısıtlı olduğu için en çok şikayeti hangi bölgede ise hangi şikayeti varsa ona yönelik tetkiklerini istiyoruz. Fazla fizik muayene bulgusu sadece şikayeti olan bölgeyi tarıyoruz. Genel olarka bir norolojik muyene yapmak gibi bir şansımız ve zamanımız mmalesef yok poliklinikte……Kaydı genelde hastanın pek alınamıyor, sadece özellikli nörolojik muayenesinde pozitiflik olan belirgin şikayeti olan hastaların anamnezini kayıt altına alıyoruz. Onun dışındaki diğer hastaları kayıt altına alma gib bir şansımız malesef yok."

"Hasta ve hasta yakını açısından bize daha uzun bir süreye ihtiyaç oluyor. Değerlendirmeyi sadece hastaya yönelik yapamıyorsunuz. Aileyi de işin içine katmak zorundasınız. Aileyi bu konuda bilgilendirmeniz ve ikna olması gerekiyor. Çocuğun eğitimden ne kadar neyi kazandığını aileye açıklamanız gerekiyor. Aileyi tatmin etmeniz gerekiyor. Çocuğun eğitmene ne kadar ihtiyacı olduğunu. Çocuğun değerlendirme süreci oldukça uzun. Çünkü her alanda herşeyi değerlendimeye çalışıyoruz. Bu en az 30dk. En çok 2 saat"

"Hasta verilerini devlet hastanesinde bilgisayara işlemek gibi bir adet şuan için söz konusu değil. Bilgi sistemi anamnez kutuları içinde doktorun notunun, anamnezinin

olabileceği yazılabileceği bir yer var. Ama hiçbir zaman vakit yetiştirip de doktorun insiyatifi ile yapılabilen birşey değil. Şuan çalıştığımız yerde doktora ayrılmış bir sekreter olmadığı için onları doldurmak zaten süre açısından yetersiz. Onun için bildiğim kadarı ile hiç kimse de bu konuda bir şey doldurmuyor. Ancak yatan hastanın dosyalarına gerekli bilgiler yazılıyor o da hikaye ve teşhisi ve yahut da epikriz."

2. Hastane Bilgi Sistemi

Kullanılabilirlik

Katılımcılar veri kaydetme sürecinde zamana karşı çalışırken aynı zamanda hastane bilgi sisteminin karmaşıklığı(HBS) ile de uğraşmaları gerektiğini düşünmektelerdir. Kayıt sürecinde HBSnin kullanılabilirliğine dayalı sorunları şu şekilde dile getirmektelerdi.

"….Aşırı derecede teferruatlı yazılmış. Bir hekimin hem hasta ile ilgili hem bunları dikte edebileceği kutucukları işaretleyebileceği veya başka seçenekleri tahlili tetkiki yapabileceği bir şey söz konusu değil. Program aynı zamanda akıllı bir program değil. Çünkü sürekli kullanılan tetkikleri laboratuarları tekrar ekrana getiren bir şey değil. Bunun için doktorun alışkanlıklarını 2 3 defada sık kullanılanlar altına alabileceği akıllı programlar lazım….."

İhtiyaca Cevap verme

Bilimsel araştırmalar için veri toplamada en çok kullanılan sistem hastane bilgi sistemi idi. Veri kaydı hasta bakımı, mali amaçlı ve araştırma amaçlı olarak kullanılabilirken, katılımcılar ilk iki nedenin ön planda olduğunu araştırma için kayıt edecek bir sistem olarak yeterli görmediklerini belirtmişlerdir.

"…..HBS var ama SGK muayene tanıları görmek ve faturalandırmak için genelde bu işlem yapılıyor. Onun dışında da herhangi bir araştırma ya da hasta takibi için malesef bilgi sistemleri kayıt sistemleri yetersiz devlet hastanelerinde."

Entegrasyon

Hastane bilgi sisteminiin merkezi bi sisteme entegrasyonu ile farklı hastanelerde, farklı kişiler tarafından değerlendirilen hastaların verilerinin ortak bir çatı altında toplanması da veri toplamaya etki eden faktörler arasında olduğu görülmüştür. Hastaların verilerinin farklı yerlerde tekrar tekrar toplanması hem verilerin duplikasyonuna hem de iş gücünün gereksiz kullanımını beraberinde getirmektedir.

"…..Bütün verilerin sisteme girilebiliyor olması sadece yerel bilgi sistemi ile sınırlı olmaması gerekiyor. Zaten girilmiş olan bütün verilerin merkezi sisteme aktarılacak bir sisteme dönüşmesi gerekiyor. Bu hale geldiğinde hasta ile kim ilgileniyor ise ilgilensin

verilerin herkes tarafından görülebilir hale gelen bir sistemin olması çocuğun tedavi/eğitim sürekliliği açısından mükemmel olur."

Her ne kadar merkezi bir sistem var olsa da tüm hastanelerin henüz bu sisteme entegre olmadığı belirtilmiştir.

"Şu anda kullandığım sistemde hastalar dış merkezden gelmişse zaten hastaya ait hiçbir bulguyu dosyada göremiyoruz. E-nabız üzerinden de baksanız genelde yayınlaşmamış bir sistem"

Entegrasyonun kişisel bazda da sağlanabildiğini belirten bir katılımcı bu kez de donanım eksikliğinden dolayı da bu tür veri aktarrımında sorunlar yaşayabildiğini dile getirmiştir. Dolayısı ile hastane dışı verilerin kalitesinin etkilendiği, verilerin yetersiz olmasına neden olduğu düşünülmektedir.

"…..diyelim ki bir cd ile gelmiş bir hasta var. Röntgenine bakacaksanız. CD ile gelen hastanın röntgenine bakacak olan önünüzdeki bilgisayarda CD okuyucu yok sadece usb hafıza kartı okuyabilen bir sistemle çalışıyorsunuz. Hastaya diyorsunuz ki "Radyoloji bölümüne gidin bu cdyi hafızaya aktarsınlar hastanenin hafızasına ben oradan bakayım" diyorsunuz"

3. Etik Faktörler

Hastaya ait verilerin toplanabilmesi için gerekli bilimsel araştırmalar için aydınlatılmış onam formunun tamamlanması sürecine ait sorunlar katılımcılar tarafından bildirilmiştir. Bu faktörler sadece etik faktörler değil aynı zamanda hasta bakım sürecine katılan hasta yakınına ait faktörlerden de sayılabilmektedir.

"…Çalıştığımız kişi insanla olduğu için kendi haklarını koruması gereken seviyede olmaıgı için onun vasisi olan ailesinden izin almak zorundasınız. Farklı bir tepkiyle kaşılaştıgınız anda anlık kayıt yapma şansımız olmayabilir Ama o çocukla ilgili goruntuleri almak istiyorsam ki bunu aile eğitim programı için hazırlıyorum bunu direk olarak aileye söylüyorum. Sizin çocugunuzla ilgili açık kamera sistemi kullanıcağım ve siz içeride olacaksınız tepkisiz kalıcaksınız ama ben çocuğunuzla çalışırken kayıt alınacak. İstediginiz zaman durdurabilirim istediğiniz zaman bu görüntüyü bilimsel amaçlı toplantılarda gösterimine izin vermiyorum diyorsanız yayınlamayacağız. Kabul edenlerle bu çekimi yaparken, ettmeyenlerle yapamıyorum…"

Araştırma Bilgi Sistemine Yönelik Öneriler

Bakım sürecinde veri toplanmasına yardımcı olabilecek bir sistemin nasıl olması gerektiği ile ilgili öneriler ve ihtiyaçlar üzerinde katılımcılar, sistemin kullanılabilir, pratik, kalıcı veri içeren, her yerden ulaşılabilir entegre, akıllı bir sistem olması gerektiğini belirtmişlerdir.

"….Hastanın onamını aldıktan sonra HBYS'nin rapor elektronik doyasından görüntüyü kendi elektronik ortamınıza hastanın onayı alındığı için rahatlıkla kaydedebilirsiniz. Monitörden direk görüntü aktarılması da söz konusu olabilir."

Bu ihtiyaçlara göre yapılacak sistemin güvenlik mahremiyet, malpraktis gibi sorunları da göz önünde bulundurmaası gerektiğini belirtmişlerdir.

"….Teknolojinin en büyük dezavantajı systemin çökmesi bir virus saldırısına maruz kalsanız yada elektronik aksamdan kaynaklı system depolanmasında sıkıntı olsa yada veritabanı çökmesine bağlı bu risk var ama bu risk her sistemde var. Bugun ana işletim sistemleri microsoftun bile böyle bir riski var Devamlı bir koruma için virus koruması sağlıyorlar"

"…..Gizliliği olduğu için özellikle onam formu malpraktis davaları gibi doktoru zorlayıcı sıkıştırıcı bir alanlar olduğu için onam formuna çok ihtiyç oluğu için pek de hastanın bilimsel aşartıma onam formları pek de sağlıklı alınamıyor. Örneğin 10 cerrahi hastadan 5-6sında anında alınıyorsa 3*4 tanesinde kaçak/sonradan olabiliyor. Hem hastalar bilgilendirilmiş olur hem de bilgileri daha sağlıklı saklanır"

4 SONUÇ

Çalışmamızda çeşitli branşlarda sağlık personelinin bilimsel araştırmalar için veri toplamasına yönelik geliştirilecek uygulama için ihtiyaçlarının analizini yapmak, geliştirilebilecek bir sistem tasarımı hakkındaki önerileri araştırılmıştır.

Çalışmada zaman kısıtı nedeni ile yeterli verinin kaydedilip toplanamadığı, hasta yoğunluğu nedeni ile bazı dönemler uzun muayene ihtiyacının bile karşılanamadığı dolayısı ile verilerin kaydı yapılamadığı belirtilmiştir. Bu durumun katılımıcılar tarafından hem veri hem hasta bakım kalitesini etkilediği belirtilmiştir.
Veri kaydına ait veri kaydı kaynaklarının bir standardının olmadığı, veri eksikliğinin bu yüzden verinin toplanamamaası yada farklı kaynaklara toplanması ile meydana geldiği ortaya çıkarılmıştır.

Veri kaydının alınamamasının başka bir yönü hastane bilgi sistemlerinin yetersiz, zaman alıcı, kullanılabilirliliğinin düşük, kullanıcının ihtiyacına cevap vermeyen sistem internet ve veritabanı hatalarına yol açması nedeni ile veri toplamada zorluklar oluşturan sistemler olduğunu düşündürmektedir.
Sadece hastane içerisinde verilerin manuel, serbest metin yada çok seçenekli olarak girilmesinin yanı sıra, dış merkez tetkiklerinin görülememesi, hastane bilgi sistemlerinin merkeze entegre olmaması ve bu verilerin depolama sorununa neden olmaktadır.

PubMed Article Recommendation System based on Collaborative Filtering

Mohammad Barakat[1] and Adil Alpkocak[2]

Dokuz Eylul University, Dept. of Computer Engineering, Izmir, Turkey
[1] mohammad.barakat@ceng.deu.edu.tr
[2] alpkocak@ceng.deu.edu.tr

Abstract. PubMed is one of the largest public databases on biological and medical sciences which is updated daily with thousands of new papers, it comprises more than 30 million citations for biomedical literature from MEDLINE, life science journals, and online books. Researchers are finding it very hard to cope with exponentially increasing numbers of biomedical literature. For this reason, it is particularly important to design a recommendation system which help researchers to find materials that are relevant to them. In this paper we propose a PubMed article recommendation system, PubGate. Our recommendation system is based on a hybrid approach using both Content-based and collaborative approach with focus at the latter. We have used Jaccard similarity to compute the similarities between users according to their liked articles and their keywords of interest, we recommended articles that have been liked by the most similar users. Collaborative filtering usually suffers from the Cold Start problem, which is related to new users or new items who still has no rating. To overcome this problem, we integrated Elasticsearch engine to recommend articles to users based on their given keywords of interest. This paper combines both search engine with collaborative approach to recommend PubMed articles to the users.

Keywords: PubMed Articles, Recommender Systems, Collaborative Filtering, Content Based, Jaccard Similarity Index, Elasticsearch.

1 Introduction

Finding relevant content in large-scale systems is becoming an exhausting process in which users have to deal with trillions of gigabytes, consume long hours, and there is no guarantee that they will be successful. Artificial Intelligence approaches are appearing at the forefront of research in information retrieval and information filtering systems, recommender systems are a good example of one such AI approach [22]. Recommender systems have been developed to make it easier for researchers to discover relevant content [3], they have been used in many domains such as movie recommendation, book recommendations, e-commerce, music recommendation, social networking recommendation, news recommendation, and article recommendation [23]. Recommendation systems can be categorized into two main categories: content-based approach, and collaborative filtering approach. In content-based approach users will be recommended items similar to the items they have liked in the past, whereas in

collaborative filtering approach its believed that users who liked the same items in the past will also like the same items in the future. In this paper we have proposed a PubMed article recommendation system based on both content-based approach and collaborative approach. Our focus was at the latter because a key advantage of using collaborative filtering approach is that there is no need to deal with the characteristics of the articles, instead of using the features of the items to determine their similarity, we calculate the similarity between the users according to their liked articles and sets of keyword.

The contributions of our work are as follows:

- Explicit user feedback: We have developed a User-friendly web application so researchers can add their keywords of interest, and like the articles they are interested in.
- Collaborative Approach: We calculated the Similarities between the users based on their liked articles and their keywords of interest. We recommended the liked articles of the neighbor users.
- Cold Start Problem: We overcame the cold start problem through generating recommendations based on user's keywords of interest through using Elasticsearch engine.

The remainder of this paper is as follows. Section 2 details related work and theory in recommender systems. Section 3 presents our methodology. Finally, section 4 presents the conclusion of our work.

2 Literature review

In general, there have been three approaches to conduct recommendations, content-based approach, collaborative filtering approach, and hybrid approach.

2.1 Content Based Approach

In content based approach, the main focus is on the content of the items or their characteristics [6][9][14][18], the user is recommended an item similar to the items he liked in the past, so in order to find similarities between the items their contents should be extracted first and then one of the popular similarity measures is applied, of these popular measures are Pearson correlation and Cosine similarity [1]. Authors presented PURE in [9], a content-based recommendation system that works on documents' titles and abstracts of the PubMed dataset. It automatically captures user preferences by using her response to the presented papers. Furthermore, PURE uses the well-known TF-IDF method and learns probabilistic model for computing relevant documents based on selected documents added by the user.

2.2 Collaborative Filtering Approach

In collaborative filtering approach items are recommended to the user based on other like-minded individuals who have similar preferences or tastes to the target user [8], the collaborative filtering has become the most widely used approach to recommend items for users [7] [11] and is divided mainly into two parts: Memory-based method and Model-based. In the memory-based a particular user is being selected, users that are similar to that user will be found based on the similarity of ratings or votings, finally items liked by those similar users will be recommended. In the model-based method a model is being constructed to describe the behavior of the user usually by using machine learning algorithms to predict the user's rating of an unrated item. Popular model-based techniques are Bayesian networks, Singular Value Decomposition, and Probabilistic Latent Semantic Analysis.

Unlike content-based approach, collaborative filtering approach can efficiently capture users' interests based on users' history behaviors [4]. Our inspiration to adopt this approach came from here because it doesn't need to deal with the content of the articles. As mentioned before collaborative filtering approach usually suffers from the cold start problem, new models have been introduced to mitigate this problem, in [7] authors presented an improved heuristic similarity measure model, their new similarity model combines the local context for common ratings of each pair users and global preference of each user ratings, their experiments showed better recommended performance and better utilization for the ratings in cold user conditions. Authors in [5] also presented a new similarity measure perfected using optimization based on neural Learning, the combination of Jaccard's similarity measure, the arithmetic average of the squared differences in votes and the values of the differences in the votes provide them with the basic elements to design a metric that obtains good results in new user cold start situations.

Two recommendation models have been proposed in [10] to address the cold start problem, the models combine a time-aware collaborative filtering (CF) model timeSVD++ with a deep learning architecture SDAE. The deep learning neural network SDAE is responsible for the extraction of item content features, while the timeSVD++ model is responsible for prediction of unknown ratings.
Other studies have taken the time sequence characteristic of user behaviors into account [4] they proposed a time-ordered collaborative filtering recommendation algorithm (TOCF), which takes the time sequence characteristic of user behaviors into account, besides they proposed a new method to compute the similarity among different users, named time-dependent similarity. Moreover, similarities between the users in [11] are calculated considering users' interest sequences. Interest Sequence can be regarded as time series data that consists of pairs of items and their ratings sorted by time sequence as indicated by the index. They assumed that users who have longer LCSIS (Longest Common Sub-IS) and more ACSIS (All Common Sub-IS) should also have more similarity in their preferences. In other studies, privacy was the main concern [16] they proposed a different privacy-preserving collaborative filtering methods along with

Restricted Boltzmann Machine (RBM)-Convolutional Neural Network (CNN) as a deep learning method.

2.3 Hybrid Approach

More than one approach was the choice of some studies, as mentioned earlier these approaches are so-called hybrid recommendation systems, these systems combine different filtering approaches to achieve better performance and to eliminate the disadvantages of solely relying on one approach. In [22] authors developed a new hybrid recommendation method based on Collaborative Filtering (CF) approaches, they used ontology to improve the accuracy of recommendations in Collaborative Filtering, in addition to that they used a dimensionality reduction technique, Singular Value Decomposition (SVD), to find the most similar items and users in each cluster of items and users which can significantly improve the scalability of the recommendation method. Meanwhile [3] they combined implicit feedback and collaborative approach together. For this work implicit feedback comes from user interactions such as users adding documents to their personal libraries, they calculated the similarities among users according to what their libraries have in common. Another Hybrid approach has been developed in [2] for news domain. Lucene was used as a search engine mainly as a content based recommender, Mahout has been used as a collaborative approach to exchange profile terms among neighboring users.

3 Method

In this section we explain briefly how our system works beginning from collecting the data, finding the similarities between the users and recommending PubMed articles.

3.1 Data Collection

We used the PubMed dataset as our main medical data resource, we downloaded more than 28 million articles, and inserted them into our PostgreSQL database. Every article is attached with a unique ID known as PMID. To every article we have inserted in the database we have inserted the abstract, authors, keywords, and MeSH terms along with it. MeSH terms or Medical Subject Headings are manually assigned vocabularies by biomedical experts who scan each article, these vocabularies describe the main topic of each article [19], we excluded articles with empty abstracts.

3.2 Calculating Similarities between users

After successful registration in our web application PubGate, users are asked to enter their keywords of interest. The system saves these keywords in the database. Figure 1 shows a screenshot for the keywords of a user.

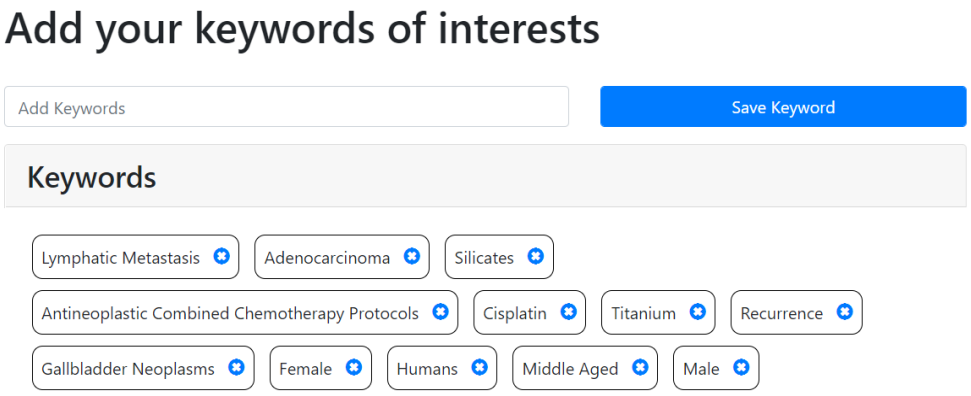

Fig. 1. Screenshot taken from PubGate showing the keywords of a user.

Users can enter an unlimited number of keywords. Each user in our system is presented as a set of keywords and likes, Figure 2 shows a screenshot for the list of liked articles for a user.

Fig. 2. Screenshot taken from PubGate showing the list of liked articles of a user.

In our system users are presented as a set of keywords and likes. Similarity between two users *u*, and *v* is calculated as follows:

$$Sim(u,v) = W_L \; L(u,v) + W_k \; K(u,v) \tag{1}$$

Where L represents likes similarity, K represents keyword similarity. Besides W is the weight factor of each term in range of 0 and 1 were $W_L + W_K \leq 1$, likes similarity and keywords similarity is calculated as follows:

$$L(u,v) = \frac{L_u \cap L_v}{L_u U\ L_v} \tag{2}$$

$$K(u,v) = \frac{K_u \cap K_v}{K_u U\ K_v} \tag{3}$$

Where L_U is the set of articles liked by user u, L_V is the set of articles liked by user v, K_U is the set of keywords of user u, and K_V is the set of keywords of user v. For better understanding of our system we demonstrate a trivial example in Figure 3.

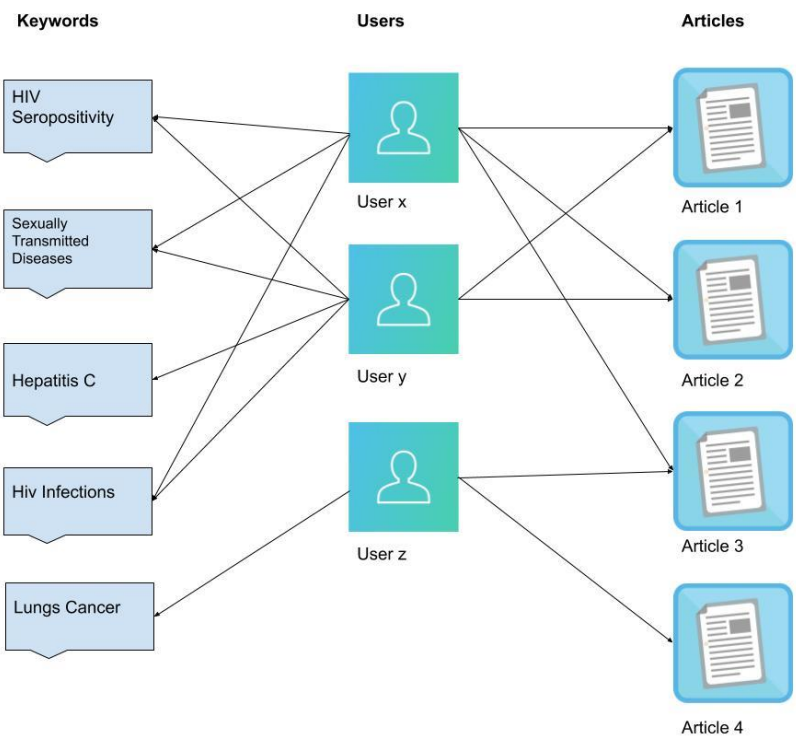

Fig. 3. Example showing the liked articles, and keywords for users x, y, and z.

From Figure 3 we fetched the values for L_x, L_y, L_z, K_x, K_y, and K_z.
L_x = {Article 1, Article 2, Article 3}

L_y = {Article 1, Article 2}
L_z = {Article 3, Article 4}
K_x = {HIV Seropositivity, Sexually Transmitted Diseases, Hepatitis C, HIV Infections}
K_y = {HIV Seropositivity, Sexually Transmitted Diseases, Hepatitis C, HIV Infections}
K_z = {Lungs Cancer}

Now using the equations in (1), (2) and (3) and assuming that weight factor for the both terms likes and keywords are equal ($W_L = W_K = 0.5$) we are able to calculate the similarity between the users as follows:

Sim (x, y) = 0.5 * 2/3 + 0.5 * 4/4 = 0.833
Sim (x, z) = 0.5 * 1/4 + 0.5 * 0/5 = 0.125
Sim (y, z) = 0.5 * 0/4 + 0.5 * 0/5 = 0

We consider two users to be similar incase their similarity measure is greater than 0.70 which is our threshold value, applying that to the example we demonstrated user x, and y are considered similar since their similarity value is 0.83 which is greater than 0.7

3.3 Recommending Articles

Finally, after calculating the similarities between all the users and finding the similar users for every user, we recommend the liked articles of the similar users. Articles that have been liked the most among all the similar users are recommended first. In our example since user x, and y are similar we recommend article 3 to user y.

Cold Start problem describes a problem of recommendation for new user, where there is no personnel network. A possible solution to the cold start problem is to use content-based filtering. Therefore, we used Elasticsearch engine to retrieve the top 5 articles containing the user's keywords. Elasticsearch engine was used as an external tool and there is no attention for us to include it in the equations or calculations part.

5 Conclusion

In this paper, we proposed a PubMed article recommendation system based on a hybrid approach including both collaborative filtering and content-based approach. We showed in an example how we calculate the similarities between the users and how articles are being recommended. Finally, we spoke about the cold start problem that the

collaborative filtering approach suffers from and how we were able to overcome this problem by suggesting to integrate our collaborative approach with Elasticsearch engine to retrieve articles for cold users based on their inserted keywords.

References

1. Agarwal, A. and Chauhan, M. (2017), "Similarity measures used in recommender systems: a study", International Journal of Engineering Technology Science and Research, Vol. 4 No. 6, pp. 619-626.
2. Pessemier, T. D., Leroux, S., Vanhecke, K., & Martens, L. (2015). Combining collaborative filtering and search engine into hybrid news recommendations. Proceedings of the 3rd International Workshop on News Recommendation and Analytics (INRA'15) at RecSys'15 14–19.
3. M. Hristakeva, D. Kershaw, M. Rossetti, P. Knoth, B. Pettit, S. Vargas, and K. Jack, "Building recommender systems for scholarly information," Proceedings of the 1st Workshop on Scholarly Web Mining, ACM, 2017, pp. 25–32.
4. Xiao, Y., Ai, P., Hsu, C. H., Wang, H., & Jiao, X. (2015). Time-ordered collaborative filtering for news recommendation. China Communications, 12(12), 53–62.
5. J. Bobadilla, F. Ortega, A. Hernando, J. Bernal A collaborative filtering approach to mitigate the new user cold start problem Knowledge Based Systems, 26 (2012), pp. 225-238
6. Chakulvisut, T., Acuna, D. E., Ruangrong, T. & Kording., K. Science Concierge: A fast content-based recommendation system for scientific publications. PLoS One 110, e0158423 (2016).
7. H. Liu, Z. Hu, A. Mian, H. Tian, X. Zhu A new user similarity model to improve the accuracy of collaborative filtering Knowledge-Based Systems (2013)
8. Sun, J., Ma, J., Liu, X., Liu, Z., Wang, G., Jiang, H., Silva, T.: A novel approach for personalized article recommendation in online scientific communities. In: Proceedings of the 46th Hawaii International Conference on System Sciences (HICSS) (2013)
9. Yoneya, T., Mamitsuka, H., 2007. Pure: a pubmed article recommendation system based on content-based filtering. Genome informatics. International Conference on Genome Informatics 18, pp. 267-276.
10. Jian Wei, Jianhua He, Kai Chen, Yi Zhou, and Zuoyin Tang. 2017. Collaborative filtering and deep learning based recommendation system for cold start items. Expert Systems with Applications 69 (2017), 29–39
11. Cheng, W., Yin, G., Dong, Y., Dong, H., & Zhang, W. (2016). Collaborative filtering recommendation on users' interest sequences. PLoS ONE, 11(5), e0155739.
12. S. Li, P. Brusilovsky, S. Su, and X. Cheng, "Conference Paper Recommendation for Academic Conferences," IEEE Access, vol. 6, 2018, pp. 17153–17164.
13. Z. Lu, Z. Dou, J. Lian, X. Xie, and Q. Yang, "Content-based collaborative filtering for news topic recommendation," in Proc. 29th AAAI Conf. Artif. Intell., 2015, pp. 217–223.
14. Kompan M., Bieliková M. Content-Based News Recommendation Proceedings of the 11th international conference E-commerce and web technologies, EC-Web 2010, Bilbao, Spain, September 1–3, Springer (2010), pp. 61-72

15. Shahin Mohammadi, Sudhir Kylasa, Giorgos Kollias, and Ananth Grama. 2016. Context-specific Recommendation System for Predicting Similar PubMed Articles. In Data Mining Workshops (ICDMW), 2016 IEEE 16th International Conference on. IEEE, 1007–1014
16. Sahoo, A. K., Pradhan, C., Barik, R. K., & Dubey, H. (2019). DeepReco: Deep Learning Based Health Recommender System Using Collaborative Filtering. Computation, 7(2), 25.
17. Wei W., Marmor R., Singh S. et al. (2016) Finding related publications: extending the set of terms used to assess article similarity. AMIA Jt Summits Transl. Sci. Proc ., San Francisco, 225–234.
18. D. Zelen´ık and M. Bielikov´a. News recommending based on text similarity and user behaviour. In Proceedings of the 7th International Conference on Web Information Systems and Technologies, WEBIST, pages 302–307, Noordwijkerhout, The Netherlands, 2011. SciTePress.
19. H.A.M. Hassan Personalized research paper recommendation using deep learning Proceedings of the 25th Conference on User Modeling, Adaptation and Personalization - UMAP, '17 (2017), pp. 327-330.
20. Lin J, Wilbur WJ. PubMed related articles: a probabilistic topic-based model for content similarity, BMC Bioinformatics , 2007, vol. 8 pg. 423
21. Eirinaki, M., Gao, J., Varlamis, I., & Tserpes, K. (2018). Recommender systems for large-scale social networks: A review of challenges and solutions. Future Generation Computer Systems, 78(1), 413–418
22. M. Nilashi, O. Ibrahim, K. Bagherifard A recommender system based on collaborative filtering using ontology dimensionality reduction techniques Expert Systems with Applications, 92 (2018), pp. 507-520 ISSN 0957-4174
23. Zeynep Batmaz, Ali Yurekli, Alper Bilge, Cihan Kaleli (2018) "A review on deep learning for recommender systems: challenges and remedies".

An Overview of Word Embeddings in Medical Domain

Nizar Ahmed[1] and Adil Alpkocak[2]

[1] Dokuz Eylul University, Izmir, Turkey
[2] Dokuz Eylul University, Izmir, Turkey
[1] nizar.ahmed@ceng.deu.edu.tr
[2] alpkocak@ceng.deu.edu.tr

Abstract. Machine learning (ML) models needs the text data to be represented numerically for identifying patterns. Word embeddings (WE) is a feature representation method that aims to transform the text into floating-point numerical vectors. Then any Machine Learning system, such as text classification system (TC), can recognize the text patterns accordingly. Word embeddings tend to create their vectors arbitrarily by training a particular dataset on neural network, taking into consideration context and syntax of the words. Therefore, the output of these networks is a floating-point numerical number which gives no sense to identify important or common terms in data that any class can share. Whereas TF/IDF feature representation technique capable to recognize the importance of a particular term, by taking into account the frequency of the term in the whole data documents. This research provides a general overview about the recent works in WE. Then as a practical application, we are planning to work on extending WE in the medical domain. We intend to create general feature representation vector depending on combining two methods, i.e. WE and Bag of Words BoW (TF/IDF). We believe that by merging both techniques we can solve the problem of randomly assigning vectors to words using WE. This problem causes some difficulties to identify medical patterns on data. Hence, TF/IDF capable to provide the importance of particular words amongst the whole data. Thus, that may help to identify medical terms and increase the performance of the classifier. We believe that this research will add more to the work on WEs and help the effort on medical applications in future.

Keywords: Word Embeddings (WE), Bag of Words (BoW), Medical Classification System, PubMed.

1 Introduction

Text classification (TC) task has been evolved during the last decade to be one of the most interesting fields in machine learning. Assigning classes to unseen data, by discovering patterns that each class can share, is the most motivating challenge in TC. However, there is one passage that a classification model has to deal with before categorizing the data. Feature representation is the step of converting the text data into an appropriate form, such as floating-point numerical vectors, to be acceptable by the classifier. The more efficient the feature representation method is used, the more ability of the classifier to discover patterns amongst data. There are two commonly used feature representation techniques: Bag of Words (BoW) and Word Embeddings (WE) [1] [2].

Bag of Words (BoW) is a technique of representing the whole-body text, such as a documents or sentences, into a list of words. These words are stored in a matrix to be calculated latter, regardless of its sentential form and ignoring their syntax, grammar and semantics relations between them. There are two main BoW methods, term frequency and Term Frequency-Inverse Document Frequency. Term Frequency (TF) is a method of calculating the frequency of a particular term in the document. This technique shows how the occurrence of a particular term is important in a document. However, some noisy terms, such as sop words, can affect calculating TF negatively due to their frequently existence in the document. Therefore, it is preferable to remove stop words before calculating TF[1]. Term Frequency-Inverse Document Frequency (TF-IDF) on the other hand, shows how a particular term is important, by calculating their occurrences, amongst the whole corpus. This technique helps to ignore insignificant terms in data, such as stop words, and focus on the important one. As a result, both methods lack the ability to capture the syntax and the sentential context of words [1].

Word Embeddings (WE) is a feature vector representation method that has the ability to solve the drawbacks of BoW techniques. WE can discover syntax and context relations between words [1] [2]. The numerical vector representation is created as a result of training neural networks, by adjusting its weights, to predict a value as an output. For example, Autoencoders is considered one type of unsupervised neural networks that is responsible for taking a word as input then encode it to a numerical vector representation as an output [3]. There is one drawback of WE as a result. The output of these networks is a floating-point numerical number which gives no sense to identify important or common terms in data that any class can share [2]. In other words, WE can give equally importance to all vocabulary in the data. For example, in a medical domain, the classifier needs to identify medical terms in the whole data rather than all vocabularies. In sentiment analysis also, a classifier needs to recognize sentimental terms as a result. Therefore, there are some attends in literature, as we will provide in the next sections, that tries to make progress in this issue.

As a result, in this research we are presenting a general overview of some works in literature about WE. Moreover, we are proposing to work on extending WE in the medical domain. We intend to create general feature representation vector depending on combining two methods, i.e. WE and Bag of Words BoW (TF/IDF). We believe that by merging both techniques we can solve the problem of randomly assigning vectors to words using WE. Consequently, that may help to identify medical terms and increase the performance of the classifier. Also, we intend to use external knowledge to provide semantics relations of the medical data. Enormous dataset resources will be used for creating the feature representation vectors such as: PubMed, clinical reports (MIMIC III). Besides, other data resources, such as WordNet and other medical dictionaries UMLS, will be employed as the external medical knowledge.

The rest of this paper will propose the following: Section 2 describes some related studies in which our research takes inspiration. Section 3 presents our methodology that explains our plans throughout this work which describes data collection, combining

feature representation techniques, and external knowledge representation phases. Finally, section 4 presents the conclusion of our work.

2 Literature work

In this section we will represent the most recent surveys and researches concerning the basic algorithms for constructing WE and extending them to work with different datasets, domains and IR systems.

2.1 Commonly used WE architectures

The best advantage of word embeddings in comparison to the other feature representation techniques, such as TF-IDF, One-Hot Encoding (Count Vectorizing), and Co-Occurrence Matrix, that it can recognize syntactic and context relationships between words. Hence the different approaches for word embeddings in literature relies on that assumption. The commonly WE systems that are frequently used in literature:

WordtoVec: T. Mikolov et al. [4] proposed a method for creating vectors by training a neural network that consists of two hidden layers. The first hidden layer is called continuous bag of words (CBOW) that predicts a target word(t) depending on its neighboring words in context word(t-1) and word(t+1). On the other hand, the second hidden layer, which is called continuous skip gram layer, is responsible for predicting the context words depending on a target word that can be found in the same sentence. WordtoVec tends to infer the meaning of a word by the company, context words, it keeps. For example, if you have two words that have similar neighbors, i.e. similar context, then these words are quite similar in meaning. Figure 1 shows a simple example of how WordtoVec can predict a target word, the center word, depending on its context and window size (represented by C in figure 1). Taking the sentence "***Analyzing white blood cells can detect leukemia.***" as an example, with a target word "***blood***" and its neighbor words. When the window size is one (C=1), it means that it takes into consideration one word after and before the target word, such as "***white***" and "***cells***" respectively. Additionally, when the window size is equal to two (C=2), it means that it takes into account two consecutive words before and after the target word, such as "***Analyzing white***" and "***cells can***" respectively.

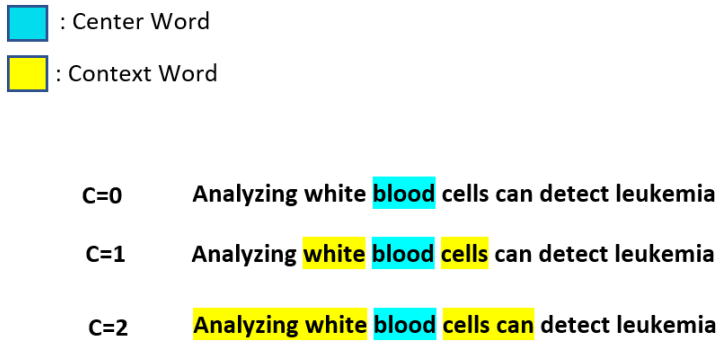

Figure 1. A simple example of how WordtoVec works

***Global Vectors for Word Representation (Glove)*:** This technique is represented by Jeffrey Pennington et al. [5], and it works the same way the Word2vec method work. The only difference that Glove has to train over huge data resources such as Wikipedia 2014 and Gigaword 5 with 50-dimension word vector representation. Moreover, they used Twitter data to pre-train their word embeddings to expand the word vector dimension to 100, 200 and 300 long. Glove is considered a new global log bilinear regression model that combines the advantages of the two major model families in the literature: global matrix factorization and local context window methods. Figure 2 shows a visualization of the word distances over a sample data set.

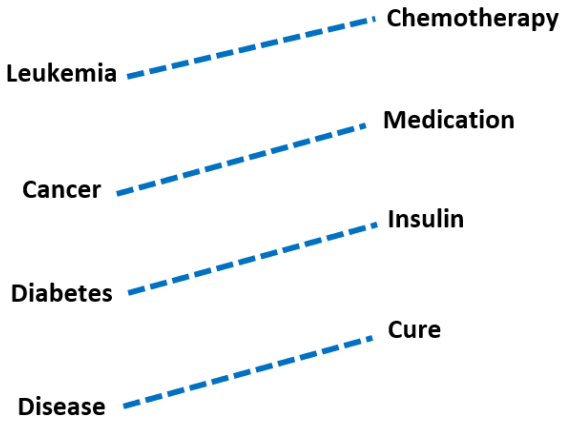

Figure 2. GloVe: Global Vectors for Word Representation.

The example in figure 2 shows how you can find a target word by taking into consideration the relation between two other related words (Words analogies). For

example, the underlying concept that distinguishes ***Leukemia*** from ***Chemotherapy***, i.e. Disease or Cure, may be equivalently specified by various other word pairs, such as ***Diabetes*** and ***Insulin*** or ***Cancer*** and ***Medicine***.

FastText: many researchers depend on assigning a distinct word vector to morphological words. Piotr Bojanowski et al. [6] proposed a word embedding technique to solve the problem of word morphology. The main idea is to take into consideration that each word is represented as a bag of its n-gram characters. Each created vector then is related to a n-gram character set of a target word. For example, given the word "***introduce***" and n = 3, FastText will produce the following representation composed of character tri-grams:

< in, int, ntr, tro, rod, odu, duc, uce, ce >

Note that the sequence <***int***>, corresponding to the word here is different from the tri-gram "***int***" from the word "***introduce*** ". This technique is considered fast even if it deals with larger corpora. Besides, it can give a word representation to those words which did not appear in the training dataset.

Context2vec: This technique is presented by Oren Melamud et al. [7], and aims to learn a sentence-based word embedding representation taking into consideration contexts around a target word. This method depends on using a bidirectional LSTM neural network to capture context words from both directions of the target word. The output layer of that network represents the embedding of the whole sentential context beside the embedding of the target word itself. Context2vect solved many NLP problems such as Polysemy and it is capable of capturing syntax and semantics of the word.

Although the mentioned approaches solved many NLP problems, they still need to be extended and expanded to deal with different datasets and different domains.

2.2 Extending Word Embeddings:

There are other techniques in literature which extend the work on creating word embeddings. Those systems rely on the previous basic approaches and add more techniques to solve many challenges:

Dealing with Different data levels:

Working in a particular dataset level is one challenge of extending the work on the word embedding systems. There are five main data levels in literature: character, word, sentence, paragraph and document levels. For example, as a character level, [6] and [8] dealt with training n-gram character set to predict word vectors. Hence, they can solve many problems related with word morphology or out-of-vocabulary words (words that didn't appear in the training set and has no vectors). [6]'s approach predicts a target word vector representation by summing the n-gram vectors of its character set so that any word doesn't appear in there training set has also its vector representation. Other research dealt with word level representation as well such as [4] and [5]. [4] created an embedding system, Word2Vec, that predict the vector of the target word depending on the context of its neighbor words and vice versa. The same thing also is done by [5]

who built an embedding system so that each word is presented by a high dimension vector and it is trained locally, based on the surrounding words, and globally over a huge corpus. However, word level methods suffer from some problems such as polysemy, out-of-vocabulary words and morphology which we explained some of their solutions previously. Furthermore, other research worked on sentence level representation such as [7]and [9] to capture contextual representation of each word. Also, sentence-based embedding methods can recognize syntax and semantic relations of the words, especially when it deals with the context words that surround the target word within the same sentence. On the level of paragraph and document-based, words embedding also took place in literature. For example [2] worked on creating a knowledge-based document-level word embeddings for text classification. His method solved many NPL problems regarding word sense disambiguation WSD, identifying semantic richness of the word, and word-sense embedded vectors.

Dealing with different dataset resources:

Another technique to extend the work on word embeddings is the use of different data resources. There are several data resources that can be employed to create word embeddings. Wikipedia, Google documents, Twitter, PubMed…. etc. are some examples of those resources. Additionally, some other resources, such as WordNet, can also be used as an external knowledge to support semantics to the created system [2]. A majority of researchers used Wikipedia documents such as [5],[10],[6] and [11] since Wikipedia provides valuable and rich information about all the applications and domains in our lives. Google news also is well-thought-out as another data resources and it has been used by [10][4] for creating their embeddings. Besides, electronic clinical notes and biomedical publications such as PubMed and MIMIC III data also were used by [9],[10], and [12] to create a medical word embedding. Other data resources also have been so beneficial to create word embeddings in literature such as: Gigaword 5 [5], Twitter [11] [5], bug reports and the source code files [13].

Dealing with different IR systems (Ranking systems, or classification system):

Extending vector embeddings to work in different Information Systems also took its place in literature. Some research employed word embeddings to be part of their ranking systems such as Cheng et al. [8]. He created a multiple resource word embedding system and used it as a feature representation method. Then he ensembled the results learned from each data resource using a learning-to-rank techniques. Xin Ye et al. [13] also used word embeddings in ranking systems. He built a document ranking system that tried to discover document similarities in corpus using word embeddings which is created from several resources. And others such as [14] also used word embeddings for his IR framework which implemented GLM using the Lucene2. On the other hand, the majority of other researchers used word embeddings representation in their classification tasks. Qingyu Chen et al. [9] created a medical based embedding for his multi-label text classification task that is applied on the Hallmarks of Cancer corpus. And other research also worked on named entity recognition such as [5] and [2] using embedding representations.

2.3 Different Embeddings with Different Data Domains/Applications:

Employing a particular word embedding depends on the domain, or the application, that you intend to use it for. For example, if you are using a word embedding system that is trained from Wikipedia or BBC news in the medical domain, the performance will be less than if you use a word embedding created from medical data [9][10]. Accordingly, you should make sure that the created word embeddings are closed to the domain that you are working on. [9][10] and [12] worked on creating medical word embedding systems. Most of the data resources that they used were collected from Pubmed and electronic clinical reports. Besides, [2] also evaluate his word embeddings on the medical Ohsumed-400 dataset which annotated with 23 cardiovascular diseases. His results were critically low when he explored classifying his medical data using his NASAI+Bable2vec embeddings. NASARI is created based on synsets from BablNet and Wikipedia, while Bable2vec is created based on Word2Vec embeddings. His data set worth to study on, specially if we tried to create our medical based word embeddings. Because theoretically using medical based word embeddings in his case will help to identify medical terms correctly in the data. some other studies tried to explore word embeddings in theirs Sentiment analysis domain. [2][11] and [15] created their embedding systems using one or more basic embeddings, such as Word2Vec accompanied with FasText, to identify sentiment polarity on their corpus. While [3] extend his word embeddings to be more specific, not general purpose, to be used on sentiment analysis domain. Finally, some other research discussed the work on computer engineering domain such as [13][2]. [13] created his word embeddings using software bug reports and the source code files. He aimed to discover the bridge between natural language statements software reports and code snippets to use it in his IR ranking system. On the other hand, [2] created several domain-based embeddings and one of them is a computer science word embedding system. He used this system to classify Computer Science Technical Reports (CSTR). As a result, the work on creating embeddings for the medical domain still need developing since it gets lower results as it has been seen in [2].

3 Extending WE using a hybrid approach

This paper only proposes an idea about extending WE in a medical domain. We will explain briefly how our system works.

3.1 Data collection and acquisition:

In this phase we intend to collect two different medical corpora. We will use the first one as a training data for constructing our hybrid feature representation system, such as PubMed and clinical reports MIMIC III (Figure 3. b and c respectively). Furthermore, we will employ the second data set as an assessment data in a classification problem for medical domain, such as clinical text annotated with ICD-10 disease codes (Figure 3. d).

3.2 Constructing and extending the WE system using a hybrid approach:

In this phase we are intending to apply several steps to create a unified vector representation. This vector represents a combination of the two feature representation approaches: BoW and WE.

Step 1: Creating vectors of the Word Embedding system:
In this step we plan to use our training dataset, as shown in figure 3 b and c, to build the embedding system. Then, we will use one of the commonly used WE, such as Word2Vec, to construct the embedding system.

Step 2: Creating BoW vector for each word:
Using the same corpus in step 1, we will use the following formula to calculate the TF/IDF weight of each term in that dataset. Let $\boldsymbol{f_{t,d}}$ represents Number of times term $\boldsymbol{t}$ appears in a document $\boldsymbol{d}$. And $\boldsymbol{V}$ represents the total number of terms in the document d.

$$TF(t)= f_{t,d} / V \qquad (1)$$

For calculating the Invers document frequency, let D represents the total number of documents in the corpus. And N represents the number of documents with term t in it.

$$IDF(t) = log(N/D) \qquad (2)$$

Then, Tf-idf weight is the product of these quantities:

$$TF\text{-}IDF=TF(t)*IDF(t) \qquad (3)$$

Step 3: Combining the results of Step 1 and 2 to create one solid vector representation.

3.3 Using external knowledge to formulate semantic space for each term in the WE:

In this phase, we will create a semantic space for each term in our vector space. We intend to use external data resources such as Unified Medical Language System (UMLS) dictionaries to provide synonyms for each term resulted in the previous section step 3 (see Figure 3. a).

3.4 Creating a classification model:

We plan to build a hybrid neural network model, depending on CNN and RNN, to classify our assessment medical corpus (Figure 3. d). And as a result, we will use three evaluation metrics, mainly Precision, Recall and F score to evaluate our classification model. Then we will compare it with other baseline systems in literature.

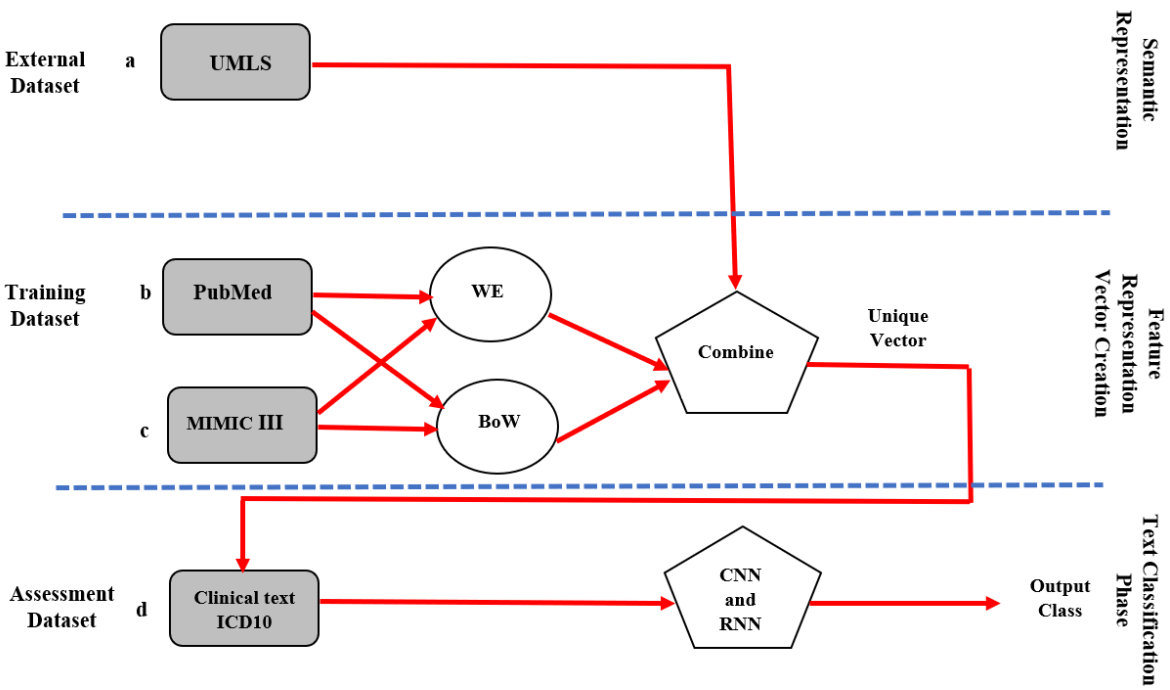

Fig. 3. The Extended WE system architecture

4 Conclusion

Word Embeddings (WE) is a feature representation method that aims to convert the text into numerical vectors. Accordingly, WE are considered an important step for so many Machine Learning (ML) applications such as text classification (TC). Any classification model can recognize patterns from the created WE vectors to classify the data. Therefore, WE tend to create their vectors arbitrarily by adjusting the weights of the neural networks. This may mislead identifying the importance of common words in data. On the other hand, Bag of Words (BoW) methods, such as Term Frequency-Inverse Document Frequency (TF-IDF), is used particularly to identify the importance of textual terms amongst the corpus. This paper provides an overview about the work on Word Embeddings. In addition, it proposes a detailed idea about combining two feature representation methods, word embeddings and bag of words (BoW) in medical domain. By merging these two methods we will ensure applying both methods' advantages to classify clinical reports to its ICD-10 codes. Furthermore, we are proposing the use of multiple data resources for creating WE and TF/IDF vectors. After that, we intend to use another external medical resource to support semantic representation in our system. We believe that this research will add more to the work on WEs and help the effort on medical applications in future.

References

[1] K. Kowsari, K. J. Meimandi, M. Heidarysafa, S. Mendu, L. Barnes, and D. Brown, "Text classification algorithms: A survey," *Inf.*, vol. 10, no. 4, pp. 1–68, 2019.

[2] R. A. Sinoara, J. Camacho-Collados, R. G. Rossi, R. Navigli, and S. O. Rezende, "Knowledge-enhanced document embeddings for text classification," *Knowledge-Based Syst.*, vol. 163, pp. 955–971, 2019.

[3] Z. Ye, F. Li, and T. Baldwin, "Encoding Sentiment Information into Word Vectors for Sentiment Analysis," *Proc. 27th Int. Conf. Comput. Linguist.*, pp. 997–1007, 2018.

[4] T. Mikolov, K. Chen, G. Corrado, and J. Dean, "Efficient Estimation of Word Representations in Vector Space," pp. 1–12, 2013.

[5] J. Pennington, R. Socher, and C. D. Manning, "GloVe: Global vectors for word representation," *EMNLP 2014 - 2014 Conf. Empir. Methods Nat. Lang. Process. Proc. Conf.*, pp. 1532–1543, 2014.

[6] P. Bojanowski, E. Grave, A. Joulin, and T. Mikolov, "Enriching Word Vectors with Subword Information," *Trans. Assoc. Comput. Linguist.*, vol. 5, pp. 135–146, 2017.

[7] O. Melamud, J. Goldberger, and I. Dagan, "context2vec: Learning Generic Context Embedding with Bidirectional LSTM," pp. 51–61, 2016.

[8] C. Li, M. Zhang, M. Bendersky, H. Deng, D. Metzler, and M. Najork, "Multi-view Embedding-based Synonyms for Email Search," pp. 575–584, 2019.

[9] Q. Chen, Y. Peng, and Z. Lu, "BioSentVec: creating sentence embeddings for biomedical texts," pp. 0–4, 2018.

[10] Y. Wang *et al.*, "A comparison of word embeddings for the biomedical natural language processing," *J. Biomed. Inform.*, vol. 87, pp. 12–20, 2018.

[11] A. B. Soliman, K. Eissa, and S. R. El-Beltagy, "AraVec: A set of Arabic Word Embedding Models for use in Arabic NLP," *Procedia Comput. Sci.*, vol. 117, no. November, pp. 256–265, 2017.

[12] Y. Shen, Q. Zhang, J. Zhang, J. Huang, Y. Lu, and K. Lei, "Improving medical short text classification with semantic expansion using word-cluster embedding," *Lect. Notes Electr. Eng.*, vol. 514, pp. 401–411, 2019.

[13] X. Ye, H. Shen, X. Ma, R. Bunescu, and C. Liu, "From word embeddings to document similarities for improved information retrieval in software engineering," *Proc. - Int. Conf. Softw. Eng.*, vol. 14-22-May-, pp. 404–415, 2016.

[14] D. Ganguly, D. Roy, M. Mitra, and G. J. F. Jones, "A word embedding based generalized language model for information retrieval," *SIGIR 2015 - Proc. 38th Int. ACM SIGIR Conf. Res. Dev. Inf. Retr.*, pp. 795–798, 2015.

[15] M. Giatsoglou, M. G. Vozalis, K. Diamantaras, A. Vakali, G. Sarigiannidis, and K. Ch, "Sentiment analysis leveraging emotions and word emb e ddings," *Expert Syst. Appl.*, vol. 69, pp. 214–224, 2017.

Automatic assignment of MESH Keywords for articles using Information Retrieval System for PUBMED

Fatih Dilmaç[1] and Adil Alpkocak[2]

[1] Dokuz Eylul University, Dept. of Computer Engineering, Izmir, Turkey
[2] Dokuz Eylul University, Dept. of Computer Engineering, Izmir, Turkey
[1] fatih.dilmac@ceng.deu.edu.tr
[2] alpkocak@ceng.deu.edu.tr

Extended Abstract

Background

With the rapid advance of technology, the volume of data collected in digital environments is growing rapidly. This data may contain very important information. But unfortunately, there is not enough time for people to capture such important information by reading such big data. Perhaps it could take millions of years to read such large data. Therefore, if these data are analyzed and interpreted on a fictional model, the desired information can be obtained in a short time. Our aim in this study is to obtain keywords by applying text mining techniques on PubMed. These keywords will give readers an idea of the text without reading the entire text. As a result, readers will be able to gain insight into the main theme of the text in a very short period of time without reading thousands of lines of text.

Motivation/Objective

In this study, we propose a system for automatic keyword extraction from a given research article. Our motivation in this study is that there are many studies on the keyword extraction. To the best of our knowledge, there is a few research done for PubMed automatic keyword extraction.

Method

First, we set up an Information Retrieval (IR) Systems for a set of research articles. We used subset of PubMed dataset containing 70 000 articles which they are written in year 2018. Then, abstract of a new article is given as query to IR systems, and received a set of documents similar to given query. Then, we considered first part of the results set. We investigated two different approaches: the first *k* documents or documents whose similarity score is greater than a threshold value of *t*. We called *k*-NN, and *t*-NN, respectively. After choosing similar document set, we consolidated the keywords and maintained keyword frequencies. Then, we assign the top *n* keywords to the new article. We also investigated different *k, t* and *n* values maximizing the performance of the system.

Experimentation and Results

In this study, we conducted separate experiments for each approach we propose. In the *k*-NN experiment, in order to find the best value of *k*, we empirically set the value

of *n* to be 11. Then we observed effects of varying *k* values from 1 to 29. We found 21 as the best value of *k*, where precision and recall values are around 0.5.

In *t*-NN experiment, we examined different *t* values varying from 20 to 200. And we observed a lower performance in comparison with *k*-NN.

Conclusion

In this paper, we proposed an approach to extract keywords from research article from PubMed. The results of the experiments showed that the proposed approach suggest keywords with a 50% matching with keywords given by authors. Inherently, we can not assume that mismatched keywords are irrelevant. A potential future study can be external relevance judgement of keywords which is not in the authors' original keyword list. As a result, we showed that the approach we proposed is valid to extract keywords from a research article.

Keywords: Text Mining, Big Data, Keyword Extraction, PUBMED

References

[1] Huadong Guo, Lizhe Wang, Fang Chen, Dong Liang Scientific big data and digital earth Chin. Sci. Bull., 59 (12) (2014), pp. 1047-1054

[2] Zhang C. et al., ―Automatic Keyword Extraction from Documents Using Conditional Random Fields, Journal of Computational Information Systems 4:3 pp 1169-1180, 2008.

[3] Rose S. et al., ―Automatic keyword extraction from individual documents‖, Text Mining: Applications and Theory, John Wiley & Sons Ltd, 2010.

[4] Y. Matsuo and M. Ishizuka. Keyword Extraction From A Single Document Using Word CoOccurrence Statistical Information. International Journal on Artificial Intelligence Tools, 13(1):157–169, 2004

Cardiopulmonary Resucitation Training with Virtual Reality

Göksu Bozdereli Berikol[1], Uğur Bilge[2], Gürkan Berikol[3]

[1] Bakırköy Dr Sadi Konuk Eğitim ve Araştırma Hastanesi, Acil Tıp Kliniği, İstanbul, Türkiye
[2] Akdeniz Üniversitesi Tıp Fakültesi, Biyoistatistik ve Tıp Bilişimi A.D, Antalya, Türkiye
[3]Karaman State Hospital, Karaman, Türkiye
gokxsu@hotmail.com

Abstract. We reviewed the literature about VR applications used in CPR training. We evaluated the virtual reality applications for improving the CPR performance and its perception of use. Despite the lack of randomized controlled trials and less number of participants, virtual reality had a positive effect on performance and perceptions of the users. Especially virtual reality with a feedback has been showed improved effects on compression rate, depth and performance scores.

Keywords: Cardiopulmonary resuscitation, medical education, virtual reality.

1 Introduction

1.1 Virtual Reality

Virtual reality(VR) is the simulation of the experience of the real world. Popularity of VR for training is arising especially in medical fields(Figure1). There are three types of virtual reality due to its level of immersion. One monitor, keyboard and a mouse can be a platform of virtual reality called non immersive VR. Only monitor, keyboard and a mouse can be a VR equipment which refers to Non immersive VR It needs no complex hardware . Semi immersive VR uses slightly more complex VR technologies like Liquid Crystal Shutter Glasses. It provides greater sense of immersion and presence than the non-immersive version. Fully immersive VR equipments are usually provided with the help of Head-Mounted Displays (HMD) or a head-coupled display for example Binocular Omni-Orientation Monitor (BOOM). A fully immersive system is achieved by displaying two identical three dimensional images at very close range to the eye which the brain processes the images into one single image(1).

Virtual reality applications are being used for practical training fields of medicine. As one of the essentials, cardiopulmonary resuscitation (CPR) training has recently been popular for virtual reality applications. Virtual reality (VR) applications are increasingly used for practical training fields of medicine. It is not only healthcare staff education, it also used in patients education which has an positive effect on learning motivation and competency on medical students(2-4). Its advantage is putting the viewer into the perspective of a patient who has progressed to injecting insulin, viewers could get a better understanding of common mistakes vs. best practices

CPR training is recently becoming popular for virtual reality applications. Here we review the literature about VR applications used in CPR training.

2 Methods

This study is conducted with PRISMA standards. Only the studies published until September 2019 are included in this review. The last search is updated in September,10 2019. The keywords are defined as "virtual reality", "cardiopulmonary resuscitation", "CPR", "VR" and searched in the databases of Pubmed and Cochrane.
All English full text papers are included with the criteria of "virtual reality used for CPR training". For the purpose of reviewing training use, the other uses of the virtual reality applications are excluded. Our primer question of the review is "Does virtual reality applications improve the CPR practice?" and secondary question is "Using the VR applications for CPR training has a positive perspective?".

3 Results

Thirty three studies in Google Scholar, 14 in the Pubmed and 10 studies in Cochrane databases were found. Twenty three of the studies are excluded due to the reasons of 8 studies with irrelevant meaning of abbrevations, 4 studies with non-available full text, 4 studies were letters to the editor and systematic review study. Five studies were seen in two or more databases. After recurrence is removed, the review was conducted within ten studies. As the types and participants of the studies had differences, the paper is reviewed systematically. Study type, participants, comparison, virtual reality type, aim, results and limitations were evaluated.
The studies are shown in the Table1 and Table 2. Most of the studies conducted for the last 5 years. Among the papers except 2 of them published in resuscitation, others are occasionally published in biomedical journals. Three of the studies are RCT and 4 qualitative analysis. Average of the participants are 58(±47,54) with a minimum 9 maximum 148 participants. The participants are defined as healthcare professionals, CPR trainers, medical students, nurses, nursing students, emergency residents and lay people users. The virtual reality type used are classified as immersive(%50), semi-immersive(%30) and non defined. Four studies that aim to measure only the compression part of CPR showed that virtual reality simulator improved the CPR performances of the participants especially in feedback groups.

Total of 580 participants had taken part, 42% of them are ACLS certified clinicians

4 studies used full immersion vr for cpr training. In ACLS trained participants, VR is found useful, easy to access and improves performance but the studies found that persuasive features of VR have can lead to unanticipatig interruptions(8,9). It is also found that the feedback from VR environment made a positive perspection on lay rescuers or no CPR educated participants(1,3,6).

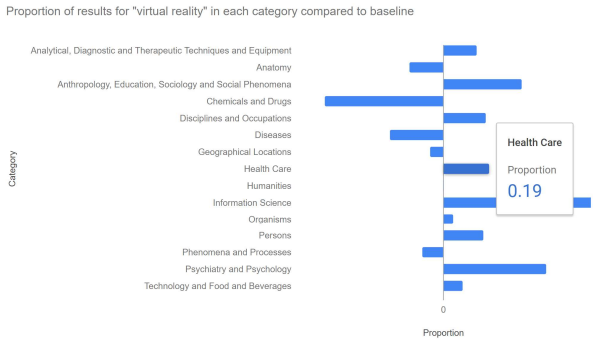

Fig. 1. The Mesh category graph of "virtual reality" with the distribution of the studies in all areas.

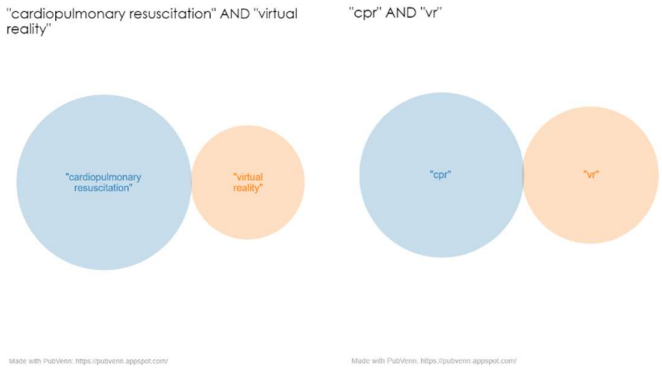

Fig. 2. The result of the studies with the relevant terms. CPR with 12091, VR with 8331 citations, both two terms 24 citations. Cardiopulmonary resuscitation with 22981 and Virtual reality with 9724 citations, both two terms 14 citations.

Table 1. The studies with the concept of virtual reality in CPR training.

STUDY	JOURNAL	AUTHORS	YEAR	STUDY
Virtual reality enhanced mannequin (VREM) that is well received by resuscitation experts.	Resuscitation	Semeraro et al	2009	Qualitative (Survey)

Interactive haptic virtual collaborative training simulator to retain CPR skills.	International Conference on Ambient Media and Systems	Khanal et al	2011	Quantitative
Motion detection technology as a tool for cardiopulmonary resuscitation (CPR) quality training: a randomised crossover mannequin pilot study.	Resuscitation	Semeraro et al	2013	Quantitative
Using a serious game to complement CPR instruction in a nurse faculty.	Computer methods and programs in biomedicine,	Boada et al	2015	Quantitative
Affordable hi-fidelity VR based CPR simulator with haptics feedback.	Haptic, Audio and Visual Environments and Games (HAVE), 2017 IEEE International Symposium	Durai et al	2017	Quantitative
Staying Alive With Virtual Humans.	Extended Abstracts of the 2018 CHI Conference on Human Factors in Computing Systems .	Morisson-Smith et al	2018	Qualitative
How the gender of a victim character in a virtual scenario created to learn CPR protocol affects student nurses' performance.	Computer methods and programs in biomedicine	Boada et al	2018	Quantitative
Design and development of a virtual reality simulator for advanced cardiac life support training.	IEEE journal of biomedical and health informatics	Vankipuram et al	2014	Qualitative
Collaborative virtual reality based advanced cardiac life support training simulator using virtual reality principles.	Journal of biomedical informatics	Khanal et al	2014	Quantitative

Clinical instructors' perceptions of virtual reality in health professionals' cardiopulmonary resuscitation education.	SAGE Open Medicine,	Wong et al	Qualitative (Survey)

Table 2. Participants, VR type and comparison of the groups of the studies.

STUDY	PARTICIPANTS	VR TYPE	COMPARISON
Virtual reality enhanced mannequin…	39 MD&LR&N	Full	-
Interactive haptic virtual collaborative..	12 BLS LR	Semi	-
Motion detection technology…	80 HCP & LR	Semi	Feedback Vs Non Feedback
Using a serious game …	109 NS	Semi	Traditional Vs Traditional + VR
Affordable hi-fidelity VR ….	16 LR	Full	VR Vs VR
Staying Alive With …	9 LR	Semi	Feedback Vs Nonfeedback
How the gender of …	41 NS	Semi	-
Design and development of a virtual reality …		Full	With Vs Without Features
Collaborative virtual reality based…	148 ACLS CC	Semi	Traditional Vs VR
Clinical instructors' perceptions ….	30 CPR Instr	Full	Before Vs After

Full: Fully Immersive; Semi: Semi Immersive; CPR: Cardiopulmonary Resuscitation, MD: Medical Doctors, N: Nurse, BS: Bystanders, CC: Chest Compression, HCP: Healthcare Professionals, ACLS-CC: ACLS Certified Clinicians

The subjects in the study reported the use of devices to be acceptable, highly realistic interaction/immersion, leading to a positive overall evaluation of virtual reality used in emergency medicine as useful(5). In one study with simulated CPR scenario compared with feedback and without feedback, there was no difference between the two groups on compression depth but increases fatigue, also the participants perceived the system easy to use with an appropriate feedback(7). The visual feedback system also can effect the perception negatively(9).

4 Discussion

Virtual reality is used in various scientific areas(Fig1). In healthcare especially it is used for the treatment of anxiety disorders as phobias(18-20), autism(21), pain control(22,23), simulation applied areas as surgery(24,25), resuscitation(4-14). There are various areas in emergency medicine which uses VR as prehospital, triage, disaster management, CPR and invasive techniques used in the emergency room(26-29).

VR training is very eligible for simulation training field in emergency medicine. As the nature of CPR training is based on simulation, VR became promising field for CPR education.

Despite lack of randomized controlled trials, less number of participants, virtual reality had a positive effect on performance and perceptions of the users. Especially virtual reality with a feedback has been showed improved effects on compression rate, depth and performance scores. Evaluation of limited parts of the CPR process, changes of the rates and depths in the CPR guidelines, different CPR training levels of the participants and no comparison of the feedback systems are common limitations of the studies. In conclusion more randomized controlled studies that includes of all parts of CPR scenarios with a large number of participants are needed.

In conclusion, VR seems to be a performance improving and usable method for CPR training especially with feedback simulators.

References

1. Onyesolu, Moses Okechukwu, and Felista Udoka Eze. "Understanding virtual reality technology: advances and applications." Adv. Comput. Sci. Eng (2011): 53-70.
2. Deutsch, Judith E. "Using virtual reality to improve walking post-stroke: translation to individuals with diabetes." (2011): 309-314.
3. Jin, Bei, Zhuming Ai, and Mary Rasmussen. "Simulation of eye disease in virtual reality." 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference. IEEE, 2006.

4. Sattar, M. U., Palaniappan, S., Lokman, A., Hassan, A., Shah, N., & Riaz, Z. (2019). Effects of Virtual Reality training on medical students' learning motivation and competency. Pakistan Journal of Medical Sciences, 35(3).
5. Semeraro, F., Frisoli, A., Bergamasco, M., & Cerchiari, E. L. Virtual reality enhanced mannequin (VREM) that is well received by resuscitation experts. Resuscitation, 80(4), 489-492. (2009)
6. Khanal, P., & Kahol, K. Interactive haptic virtual collaborative training simulator to retain CPR skills. In International Conference on Ambient Media and Systems (pp. 70-77). Springer, Berlin, Heidelberg (2011).
7. Semeraro, F., Frisoli, A., Loconsole, C., Bannò, F., Tammaro, G., Imbriaco, G., ... & Cerchiari, E. L. Motion detection technology as a tool for cardiopulmonary resuscitation (CPR) quality training: a randomised crossover mannequin pilot study. Resuscitation, 84(4), 501-507. (2013).
8. Boada, I., Rodriguez-Benitez, A., Garcia-Gonzalez, J. M., Olivet, J., Carreras, V., & Sbert, M. Using a serious game to complement CPR instruction in a nurse faculty. Computer methods and programs in biomedicine, 122(2), 282-291. (2015).
9. Durai, S. V., Arjunan, R., & Manivannan, M. Affordable hi-fidelity VR based CPR simulator with haptics feedback. In Haptic, Audio and Visual Environments and Games (HAVE), 2017 IEEE International Symposium on (pp. 1-5). IEEE. (2017).
10. Morrison-Smith, S., Yao, H., Wang, I., Lok, B., & Ruiz, J. Staying Alive With Virtual Humans. In Extended Abstracts of the 2018 CHI Conference on Human Factors in Computing Systems (p. LBW038). ACM. (2018).
11. Boada, I., Rodriguez-Benitez, A., Thió-Henestrosa, S., Olivet, J., & Soler, J. How the gender of a victim character in a virtual scenario created to learn CPR protocol affects student nurses' performance. Computer methods and programs in biomedicine, 162, 233-241. (2018).
12. Vankipuram, A., Khanal, P., Ashby, A., Vankipuram, M., Gupta, A., DrummGurnee, D., ... & Smith, M. Design and development of a virtual reality simulator for advanced cardiac life support training. IEEE journal of biomedical and health informatics, 18(4), 1478-1484. (2014).
13. Khanal, P., Vankipuram, A., Ashby, A., Vankipuram, M., Gupta, A., Drumm-Gurnee, D., ... & Smith, M Collaborative virtual reality based advanced cardiac life support training simulator using virtual reality principles. Journal of biomedical informatics, 51, 49-59. . (2014).
14. Wong, M. A. M. E., Chue, S., Jong, M., Benny, H. W. K., & Zary, N. Clinical instructors' perceptions of virtual reality in health professionals' cardiopulmonary resuscitation education. SAGE Open Medicine, 6, 2050312118799602. (2018).
15. Leary, M., McGovern, S. K., Chaudhary, Z., Patel, J., Abella, B. S., & Blewer, A. L. Comparing bystander response to a sudden cardiac arrest using a virtual reality CPR training mobile app versus a standard CPR training mobile app. Resuscitation, 139, 167-173.(2019)
16. Cerezo, C. E., Segura, F. M., Melendreras, R. R., García-Collado, Á. J., Nieto, S. C., Juguera, L. R., ... & Pardo, M. R.. Virtual reality in cardiopulmonary resuscitation training: a randomized trial. Emergencias: revista de la Sociedad Espanola de Medicina de Emergencias, 31(1), 43-46.(2019)
17. Judd T, Young AP48 Virtual reality fully immersive interactive technology. Can this improve medical students' preparedness for resuscitation?BMJ Simulation and Technology Enhanced Learning 4:A75.(2018)
18. Wiederhold, B. K., & Wiederhold, M. D. Virtual reality therapy for anxiety disorders: Advances in evaluation and treatment. American Psychological Association (2005).

19. Opdyke, D., Williford, J. S., & North, M. Effectiveness of computer-generated (virtual reality) graded exposure in the treatment of acrophobia. Am J psychiatry, 1(152), 626-28 (1995).
20. Botella, C., Baños, R. M., Perpiñá, C., Villa, H., Alcaniz, M., & Rey, A. Virtual reality treatment of claustrophobia: a case report. Behaviour research and therapy, 36(2), 239-246(1998).
21. Strickland, D. Virtual reality for the treatment of autism. Studies in health technology and informatics, 81-86 (1997)
22. Levin, M. F., Snir, O., Liebermann, D. G., Weingarden, H., & Weiss, P. L.. Virtual reality versus conventional treatment of reaching ability in chronic stroke: clinical feasibility study. Neurology and therapy, 1(1), 3 (2012)
23. Malloy, K. M., & Milling, L. S. The effectiveness of virtual reality distraction for pain reduction: a systematic review. *Clinical psychology review*, *30*(8), 1011-1018 (2010).
24. Satava, R. M. Virtual reality surgical simulator. Surgical endoscopy, 7(3), 203-205(1993)..
25. Gurusamy, K. S., Aggarwal, R., Palanivelu, L., & Davidson, B. R. Virtual reality training for surgical trainees in laparoscopic surgery. Cochrane database of systematic reviews, (1) (2009).
26. Andreatta, Pamela B., et al. "Virtual reality triage training provides a viable solution for disaster-preparedness." Academic emergency medicine 17.8 (2010): 870-876.
27. Vincent, Dale S., et al. "Teaching mass casualty triage skills using immersive three-dimensional virtual reality." Academic Emergency Medicine 15.11 (2008): 1160-1165.
28. Cone, D. C., Serra, J., & Kurland, L. (2011). Comparison of the SALT and Smart triage systems using a virtual reality simulator with paramedic students. European journal of emergency medicine, 18(6), 314-321.
29. Kobayashi, L., Zhang, X. C., Collins, S. A., Karim, N., & Merck, D. L. (2018). Exploratory application of augmented reality/mixed reality devices for acute care procedure training. Western Journal of Emergency Medicine, 19(1), 158.