



Makale / Research Paper

Travma Sonrası Stres Bozukluğunun Derin Öğrenme Yöntemleri ile Tespiti

Engin SEVEN, Cansın TURGUNER, Muhammed Ali AYDIN

Bilgisayar Mühendisliği, İstanbul Üniversitesi-Cerrahpaşa, İstanbul, Türkiye
engin.seven@ogr.iuc.edu.tr

Received/Geliş: 25.06.2022

Accepted/Kabul: 04.10.2022

Öz: Travma sonrası stres bozukluğu (TSSB), kişinin yaşadığı travmatik bir olay sonrasında ruhsal ve fiziksel hayatını olumsuz yönde etkileyen psikiyatrik bir sorundur. Hastalığın erken aşamada fark edilip tedavi edilmemesi bipolar bozukluk, anksiyete veya intihar eğilimi gibi olumsuz sonuçlar ortaya çıkarabilmektedir. TSSB nin erken aşamada tespiti için yapay zeka temelli bir model geliştirilmiştir. Yapılan çalışmada K-En Yakın Komşu algoritması, Destek Vektör Makineleri, Karar Ağaçları, Gaus Naive Bayes ve Yapay Sinir Ağları kullanılmış Covid-19 pandemisi devam ederken tıp öğrencilerinden toplanan veri seti üzerinde testler gerçekleştirilmiştir. Yapılan çalışmada doğruluk, kesinlik, hassasiyet ve f1 skoru değerleri karşılaştırmalı incelenmiştir. Yapay sinir ağları 0,987 doğruluk oranı ile en iyi sonucu elde etmiştir. Ayrıca 0,966 f1 skoru ile yapay sinir ağları en iyi TSSB tahmininde bulunmuştur.

Anahtar Kelimeler: Travma sonrası stres bozukluğu; Derin öğrenme; Akıllı teşhis; Özellik Seçimi

Detection of Post Traumatic Stress Disorder with Deep Learning Methods

Abstract: Post-traumatic stress disorder (PTSD) is a psychiatric problem that negatively affects a person's mental and physical life after a traumatic event. If the disease is not recognized and treated at an early stage, negative consequences such as bipolar disorder, anxiety or suicidality can occur. An artificial intelligence-based model has been developed for the early detection of PTSD. In the study, K-Nearest Neighbor algorithm, Support Vector Machines, Decision Trees, Gaus Naive Bayes and Artificial Neural Networks were used and tests were carried out on the dataset collected from medical students during the Covid-19 pandemic. In the study; accuracy, precision, recall and f1 score values were examined comparatively. Artificial neural networks achieved the best result with an accuracy rate of 0,987. In addition, artificial neural networks found the best PTSD prediction with an f1 score of 0,966.

Keywords: Post-traumatic stress disorder; Deep learning; intelligent diagnosis; Feature selection

1. Giriş

Travma Sonrası Stres Bozukluğu (TSSB); doğal afet, terör eylemi, savaş, cinsel şiddet, adam kaçırmaya ve şiddet içeren saldırı gibi travmatik bir olayı doğrudan yaşamış veya yaşanan olaya tanık olmuş kişilerde görülebilen bir psikiyatrik bozukluktur [1]. TSSB, bireylerin hem zihinsel hem de fiziksel işlevlerini etkileyebilmektedir. Ayrıca psikiyatrik durumların ve fiziksel hastalıkların varlığı ile ilişkilidir. Tüm TSSB hastaları, uyku kalitesinin ve miktarının azalmasından, dikkat

Bu makaleye atıf yapmak için

Seven E., Turguner C., Aydın M. A., "Travma Sonrası Stres Bozukluğunun Derin Öğrenme Yöntemleri ile Tespiti", El-Cezeri Fen ve Mühendislik Dergisi, 2022, 9 (4); 1274-1281.

How to cite this article

Seven E., Turguner C., Aydın M. A., "Detection of Post Traumatic Stress Disorder with Deep Learning Methods", El-Cezeri Journal of Science and Engineering, 2022, 9 (4); 1274-1281.

bozukluğundan, duygularını kontrol etmekte zorlanmaktan ve öfke kontrol bozukluklarından muzdariptir. Bu sebeplerden dolayı sıklıkla kabus gören TSSB hastaları önemli ölçüde artan intihar eğilimine sahip olabilir. TSSB, savaş ve çatışma alanlarında yaygın olduğu bilinmekle birlikte orta ve alt gelir grubuna dahil ülkelerde de yaygın olarak görülebilir. Savaş ve çatışma bölgelerinde yaşayan çocuklar alışılmadık şekilde tehdit edici veya felaket olarak algılanan bir olaya gecikmiş veya uzun vadeli bir tepki olarak ortaya çıkabilen TSSB geliştirme riski altındadır [2].

TSSB her yaşta insanı etkileyebilir. Çocukların yaklaşık olarak üçte ikisi çocukluk çağı dönemlerinde çoğunlukla kişilerarası şiddet biçiminde travmatik bir olay yaşamış veya yaşanan olaya şahit olmuştur [3]. Travmatik olaydan sonra semptomlar ortaya çıkmadan önce genellikle ilk birkaç hafta yada ilk aylarda gizil olarak meydana çıkmak da olup ilerleyen aşamada tekrar etmesi beklenir [4]. Travma sonrası stres bozukluğundan etkilenen insanlar yaşanan travmayı hatırlama veya kabuslar yoluyla yeniden deneyimleme eğilimindedir. Bu insanlar kendilerini toplumdan uzaklaşmış ve duygusal olarak yetersiz hissedebilir. Bundan dolayı çoğu zaman tepkisiz olma eğilimindedirler ve neşeli ruh halini yaşamakta zorlanabilirler. Kendilerine travmatik olayı hatırlatabilecek etkinliklerden ve durumlardan kaçınırlar. Tipik olarak, bir uyanıklık durumunda kalırlar ve her şeyden kolayca irkilme eğilimindedirler. TSSB belirtileri ortaya çıkmış birçok kişi uyku sorunları yaşadığını bildirir. Bu belirtiler tedavi edilmediği durumlarda hastalık kronikleşmeye başlar ve bu durum anksiyete, depresyon ve madde bağımlılığı gibi kişinin ruhsal ve fiziksel sağlığını bertaraf edecek olası sonuçlara neden olur. Bu bozukluğu olan çoğu insan bir dereceye kadar iyileşirken, bazı durumlarda değişiklikler kroniktir ve kişinin mental sağlığında kalıcı bir değişikliğe neden olabilir.

TSSB teşhisi, sırasıyla dört gruptan birinin semptomlarını içerir: ilk olarak izinsiz giriş (örneğin, kabuslar ve geriye dönüşler) ikinci olarak kaçınma (örneğin, düşünceler ve duygular) üçüncü olarak bilişsel ve ruhsal durumda olumsuz değişiklikler son olarak ise uyarılma ve tepkisel davranışlarda değişiklikler (örneğin, depresyon veya uykusuzluk) ortaya çıkabilir [5].

TSSB belirtileri izlenmeye başlanmış ve hastanın durumundan şüpheleniliyorsa bir klinisyen genellikle TSSB teşhisi koymak için tasarlanmış çeşitli ölçeklerden birini kullanarak bir görüşme düzenleyecektir. Klinisyenlerin yaygın olarak başvurdukları TSSB ölçeği, Ruhsal Bozuklukların Tanısal ve İstatistiksel El Kitabında yer alan Klinisyen Tarafından Uygulanan TSSB Ölçeği isimli ölçek (CAPS) kullanılır [6]. Bir klinisyenin anketi kullanarak bir hasta görüşmesi yapması ve belirtilerin sıklık ve yoğunluğa göre çeşitli semptomlara bir şiddet derecesi ataması yaklaşık 60 ile 90 dakika arasında gerçekleşir [6].

Yapay Sinir Ağları (YSA) uygulamaları, ses tanımadan kanser teşhisine kadar çok geniştir. TSSB hastalarının ve sağlıklı bireylerin ayırt edilmesinde kullanılarak sınıflandırılmasına ilişkin bir çalışmanın etkili olacağı düşünülmektedir. Bozuklukların sınıflandırılmasını iyileştirmek, risk faktörlerini ve tedavi sonuçlarını tahmin etmek önemli bir konudur. Kişiye özel tedavi seçimini iyileştirmek için makine öğrenme teknikleri uygulanabilmektedir [7]. Travma sonrası stres bozukluğuna neden olan mekanizmaları anlamak ve en uygun tedaviler ve teşhis araçları geliştirmek için bazı engeller mevcuttur. TSSB klinik ve biyolojik heterojenlik sunan bozukluklar olduğundan makine öğrenimi ile daha iyi sonuçlar elde etmek için uygun bir yaklaşımdır.

Bu çalışmada daha yüksek doğrulukta TSSB teşhisi koymak için odaklanılmış, makine öğrenmesi ve derin öğrenme algoritmaları kullanılmıştır. Farklı parametreler altında model iyileştirmeleri analiz edilerek TSSB nin tespitinde başarı oranı arttırılmaya çalışılmıştır.

2. Literatür Özeti

Bu çalışma kapsamında yapılan literatür taramasında TSSB için yapılandırılmış psikiyatrik verilerin analizi için veri madenciliği yöntemlerinin uygulanabilirliğini gösterdiği 51'i TSSB, 51'i TSSB dışında psikiyatrik tanıları olan 102 yatan hastaya akıllı veri analiz yöntemlerinden biri olan rastgele orman sınıflandırıcısı ve destek vektör makineleri kullanılarak tanıyı tahmin etmek için birkaç model oluşturulmuştur [8]. Bir diğer çalışmada Dünya Sağlık Örgütü'nün Dünya Ruh Sağlığı Araştırmalarına dayalı olarak 24 ülkede yürütülen anketlerinde 47.466 rapor elde edilmiş olup makine öğrenimi yöntemlerinden rastgele ormanlar, liner regresyon, süper öğrenci algoritmaları test edilmiştir. Kişilerin geçmişleri hakkındaki bilgileri TSSB'yi öngören bir model geliştirmek için kullanıldı [9]. Demokratik Kongo Cumhuriyeti'nde terhis edilmiş askerler üzerinde yapılan çalışmada rastgele orman algoritması kullanılarak şiddet suçları işlemenin TSSB ile ilişkisi araştırılmıştır. 367 Kongolu eski savaşçılardan oluşturulan bir örneklem üzerinde yapılan analizlerde yaşam boyu yaşanan travmatik olayların sayısının travma sonrası stresin ana yordayıcısı olduğunu ortaya koymuş ek olarak travmatik olaylar ve travma sonrası stres arasındaki ilişkinin terhis edildikten yıllar sonra bile güçlü kaldığını ifade etmişlerdir [10]. Görevlerinden evlerine dönen çoğunluğu erkek olmak üzere 567 askerin travma sonrası stres bozukluğu açısından risk altında oldukları ve risk durumlarına göre belirlenmesinin önemli olduğu ayrıca askerler için alınacak kararlara rehberlik edilmesi gerektiği vurgulanmıştır. İlgili askerler için erken tanımlama, erken müdahaleleri ihtiyacı olanlara yönlendirebilir ve böylece kronik TSSB'nin gelişmesini engeller. Burada makine öğrenimi algoritmalarından destek vektör makinaları yönteminin uygulanmasıyla askerlerde travma sonrası stres gelişiminin erken aşamada tespiti için potansiyelleri analiz etmiştir [11]. Sosyal medya platformlarından olan twitter kullanıcılarında depresyon ve Travma Sonrası Stres Bozukluğunun ortaya çıkışını tahmin etmek için Rastgele orman algoritması ile deneyler gerçekleştirilmiştir. Twitter verileri 174 kişiden (63 TSSB, 111 sağlıklı) toplanmış olup analizler gerçekleştirilmiştir [12]. Yapılan çalışmada, 300 kişiye açık uçlu çevrimiçi anket uygulanmış olup ankete katılan kişilerin 150 TSSB belirtileri gösteren hastalardır. Anket yardımı ile hastaları travma sonrası stres bozukluğu açısından taramak için otomatik bir değerlendirme sistemi sunulmuştur. Karar ağacı, saf Bayes, destek vektör makinesi ve ürün puan modeli adı verilen alternatif bir sınıflandırma yaklaşımı dahil olmak üzere dört makine öğrenimi algoritması kullanılmıştır [13].

Gaziler arasındaki intihar oranları ve intihar düşüncesinin travmaya özgü belirleyicilerinin kanıtlarını ve bunlar arasındaki karmaşık ilişkileri açıklamak için yapılan çalışmada, Irak ve Afganistan'da görev yapan ulusal bir gazi örneği ele alınmıştır. Elektronik mail yolu ile yapılan çalışmada 2061 askerin görev öncesindeki ruhsal durumu, askeri faktörler, travmatik görev deneyimleri, intihar düşüncesi arasındaki cinsiyete özgü ilişkileri incelemek için makine öğrenimini algoritmaları test edilmiştir. Bulgular, erkekler için depresyon, travma sonrası stres bozukluğu (TSSB) ve somatik şikayetleri içeren çeşitli ilişkilerde birleşti. Sevk sırasında cinsel taciz, TSSB ve depresyon ile etkileşime giren ve kadınlar arasında SI ile daha güçlü bir ilişki gösteren kilit bir faktör olarak ortaya çıktı. Bulgular, erkekler için depresyon, travma sonrası stres bozukluğu (TSSB) ve somatik şikayetleri içeren çeşitli ilişkiler olduğunu ortaya koydu. Sevk sırasında cinsel taciz, TSSB ve depresyon gibi belirtileri olan kadınlar arasında intihar düşüncesi arasında güçlü bir ilişki olduğunu ortaya konulmuştur [14]. Yapılan bir diğer çalışmada yüksek düzeyde travmatik deneyime sahip yerinden edilmiş bireylerde (mülteciler) bilgisayar tabanlı bir görevle ölçülen riskli davranışı değerlendiren ilk çalışma olduğu ifade edilmiş olup stokastik gradyan kullanılarak analiz edilmiştir. Mevcut çalışmada, yüksek risk alma davranışı savaş ve işkence gibi organize şiddete az ve çok maruz kalan bireylerde ve ek olarak ev içi ve aynı zamanda kişilerarası olmayan tehditler de dahil olmak üzere yüksek düzeyde yaşam boyu travmatik olaylara maruz kalma ile tahmin edildi [15]. Birleşik Krallık (Birleşik Krallık) Silahlı Kuvvetlerinde görev yapan veya yakın zamanda görev yapmış 13.690 kişide olası TSSB'nin belirlenmesi için denetimli makine öğrenimi

sınıflandırıcılarından destek vektör makinaları, rastgele orman, yapay sinir ağları gibi algoritmalar kullanılmıştır. TSSB'nin teşhisinde özellikle Performansa katkıda bulunan değişkenler olarak alkol kötüye kullanımı, cinsiyet ve dağıtım durumu gibi faktörler ön plana çıkmıştır. Geliştirilen model ile halk sağlığı üzerindeki yükü büyük ölçüde azaltabilir ve belirtilerin ortaya çıkmasından önce erken müdahaleyi sağlayarak operasyonel verimliliği iyileştirebilir [16].

Yaptığımız çalışmada Covid-19 pandemisinin insanlar üzerinde bıraktığı travma sonrası stres bozukluğunun tespit edilmesi için yapay zeka algoritmalarından faydalanılmış ve karşılaştırmalı analizler yapılmıştır. Elde edilen sonuçlar yapay sinir ağlarının daha başarılı tahminlerde bulunduğunu göstermiştir. Bu çalışmanın sonucunda kişilerin yaşadığı toplumsal yada bireysel travmatik olaylar sonrasında travma sonrası stres bozukluğunun erken aşamada tespit edilmesinin önemli olduğu olası anksiyete, bipolar bozukluk ve intihar eğilimlerini önlemede yardımcı olacağı düşünülmektedir. Covid-19 sonrası TSSB tespiti için kullanılan modeller 0,765 ile 0,987 doğruluk değerleri ile tahminlerde bulunmuştur.

3. Materyal ve Metot

3.1. Materyal

Yapılan çalışmada Covid-19 pandemisinin zirve yaptığı dönemde Amerika Birleşik Devletlerinde bulunan tıp öğrencilerinden anket yoluyla veri seti [19] toplanmıştır. Veri toplama sürecinde iletişime geçilen 2511 öğrenciden 741 yanıt alınmıştır. Katılımcılardan %63,9 kadın, %35.1'i erkek ve %1.6 farklı bir cinsiyet kimliğinden oluşmaktadır. Veri seti TSSB tanısında kullanılmak üzere onaylanmış iki ruh sağlığı tarama ölçeğini içermektedir. İlk olarak Genelleştirilmiş Anksiyete Bozukluğu-7 (Generalized Anxiety Disorder-7) kullanılmış ikinci olarak Birinci Basamak TSSB (Primary Care-Post Traumatic Stress Disorder-5) kullanılmıştır. GAD-7 puanlama sistemi ayakta tedavi ortamında doğrulanmıştır. Ölçeğin puan aralıkları şöyledir: hafif (5-9 puan), orta (10-14) veya şiddetli (15 +) anksiyete semptomlarını belirlemek için 21 puanlık bir puan kullanır [17]. PC-PTSD-5 beş adet evet/hayır sorusu sormaktadır. Üç veya daha fazla "evet" yanıtı pozitif belirti olarak işaretlenmektedir [18]. Algılanan stres ve endişeler, "hiç" (1) ile "biraz" (4) ve "son derece" (7) arasında 7 puanlık tek kutuplu bir ölçek kullanılarak katılımcılar tarafından cevaplanmıştır.

Bu ölçekler ile acil tıp doktorları üzerindeki pandeminin etkilerini inceleyen yayınlanmış bir ankette alınan öğrencilerin pandemi ile ilgili endişelerini ortaya çıkarmak için sorularla desteklenmiştir. Nihai anket 29 Likert, çoktan seçmeli sorulardan oluşmaktadır [19]. Tıp fakültesi dekanları tarafından gözden geçirilen anket, öğrenci temsilcilerinden gelen üç hatırlatma ile e-posta yoluyla dağıtıldı. Sonuçlar isimsiz olarak toplanmıştır.

3.2. Metot

Çalışmamızda en yüksek doğruluk oranı ile TSSB tanısını koymak için k-en yakın komşu, destek vektör makinaları, karar ağacı, gaus naive bayes ve yapay sinir ağları gibi algoritmalar veri seti üzerinde test edilmiştir. Yapay sinir ağlarına ait hiper parametreler en yüksek doğruluk oranı için seçilmiştir. Dört katmanlı bir mimarı oluşturulmuş aktivasyon fonksiyonu olarak relu tercih edilmiştir. Optimizasyon algoritması olarak Adam seçilmiş parti boyutu (batch size) 20 olarak ayarlanmıştır.

K-En Yakın Komşu algoritması: K-en yakın komşu algoritması örüntü tanıma ve istatistiksel yöntemlerden biridir. KNN algoritmasında temel ana fikir özellik uzayında incelenen bir örneğin en benzer k örneğinin çoğu belirli bir kategoriye aitse, incelenen örneğin de bu kategoriye ait olduğu

düşünülmektedir. Bu algoritma yöntemi sınıf alanını tanımlamak yerine sınıf karar vermede yalnızca çok az sayıda bitişik örnekle ilişkiler kurar. Sonuç olarak sınıf alanında daha fazla çapraz veya örtüşen örnek kümeleri için diğer sınıflandırma yöntemlerinden daha uygun olabilmektedir [20].

K-en yakın komu sınıflandırılmasında kullanılan hiper parametreler şu şekilde seçilmiştir. n_neighbors 3 olarak belirlenmiştir. Ağırlıklar (weights) her kümedeki tüm noktalar eşit ağırlıkta olması için uniform seçilmiştir. Yaprak boyutu (leaf_size) 30 olarak belirlenmiştir. Algoritma parametresi brute-force search olarak seçilmiştir.

Destek Vektör Makinaları: Denetimli Öğrenme algoritmalarından en sık başvurulan yöntem olan Destek Vektör Makinaları daha önceden etiketlenmiş bir dizi eğitim verisine dayalı olarak nesnelerin sınıflandırılmasında kullanılan bir model olup genelleştirilmiş doğrusal sınıflandırma algoritmalarıdır [21]. Destek vektör makinaları için hiper parametre seçimi şu şekilde yapılmıştır.

Regülasyon (l2) ceza puanı 1 olarak seçilmiştir. Kernel değeri olarak noktaların benzerliğini normal dağılıma göre hesaplaması için Radian Basis Function(RBF) tercih edilmiştir. Veri dağılımının genişliğini kontrol etmek için Gamma parametresi auto olarak ayarlanmıştır.

Karar Ağacı: Bir karar ağacı genellikle verilerin analizi için kullanılan bir denetimli öğrenme algoritmasıdır. Bu algoritma regresyon ve sınıflandırma problemlerini gerçekleştirebilir. Bir karar ağacı algoritması karar düğümlerini (Bir özneliğin değerini test edin), kenarları (Bir testin sonucu ve bir sonraki düğümlerle bağlantı kurun) ve yaprak düğümünü (sonucu tahmin edin) bir araya getirir ve eksiksiz bir karar ağacı yapısı oluşturur [22]. Kara Ağacı Sınıflandırma (Decision Tree Classifier) algoritması için hiper parametreler şu şekilde seçilmiştir.

İlk olarak kiriter parametresi gini olarak seçilmiştir. Her düğümlerde bölmeyi seçmek için kullanılan splitter parametresi en iyi bölmeyi seçmek için best olarak ayarlanmıştır. Bir dahili düğümü bölmek için gereken minimum örnek sayısı min_sample_split 2 olarak ayarlanmıştır.

Gaussian Naive Bayes: Bu algoritma gauss normal dağılımını takip eder ve zaman ekseninde sürekli olan verileri destekler. Genel olarak, Naive bayes, girdi özelliği dağılımından bir sınıflandırma etiketi çıkarmak için bayes kuralının sonlu olasılığını kullanır. Koşullu sonlu olasılık, bir olayın meydana gelme olasılığı ile daha önce gerçekleşmiş başka bir olayın olasılığı arasındaki ilişkinin gösterilmesidir. Bu algoritma sınıflandırıcıları özelliklerin birbirinden bağımsız olduğunu varsayar [23].

Yapay Sinir Ağları: Yapay Sinir Ağları, bir makine öğrenme algoritmasıdır. Eldeki verilerin cevaplarının önceden bilinmesi ve cevaplara göre sistemin tasarlanması gerekir. Gerçekleştirilen bu adımlara eğitim veya öğrenme olarak isimlendirilir. Eğitim süreci içerisinde insan beynindeki bilginin öğrenimi aşamasında olduğu gibi beyinde gerçekleştirilen değişimler taklit edilmektedir. Kullanılan algoritma insan beyinde olduğu gibi öğrenme kabiliyetine birbirine son derece bağlı bir içyapı vasıtasıyla ulaşılır. Bu özellikler örüntü tanıma ve veri sınıflandırma gibi doğrusal olmayan problemlerin çözümü için uygun hale getirmiştir.

Modelin hiper parametreleri şu şekilde ayarlanmıştır. Tam bağlantılı 4 katmandan oluşan bir mimari oluşturulmuştur. İlk katmanda 59 nöron bulunmaktadır. İlk katmanda kullanılan aktivasyon fonksiyonu Leaky Relu olarak belirlenmiştir. İkinci katmanda 32 adet nöron olup aktivasyon fonksiyonu Leaky Relu tercih edilmiştir. İkinci katman ile üçüncü katman arasında dropout 0.4 olarak ayarlanmış ve aşırı öğrenmenin önüne geçilmeye çalışılmıştır. Üçüncü katmanda 16 adet nöron olup aktivasyon fonksiyonu Relu olarak ayarlanmıştır. Son katman olan çıkış katmanı


aktivasyon fonksiyonu sigmoiddur. Kayıp fonksiyonu olarak binary_crossentropy seçilmiş optimizasyon algoritması için Adam algoritması ayarlanmıştır.

4. Bulgular ve Tartışma

Yapılan çalışmada 29 adet soru 741 kişi tarafından cevaplanmıştır. Yapılan anket çalışması içerisinde anksiyete seviyesini ölçen 7 adet soru, travma sonrası stres bozukluğunu ölçen 5 adet soru ayrıca pandemi ile ilgili endişe seviyelerini ölçen sorular sorulmuştur. Veri seti içerisinde 59 adet özellik seçilmiş ve K-en yakın Komşu, Destek Vektör Makinaları, Karar Ağaçları, Gaus Naive Bayes ve Yapay Sinir Ağları ile eğitimler gerçekleştirilmiş modelin doğruluk sonuçları Tablo 1’de verilmiştir. Doğruluk oranları karşılaştırıldığında en kötü tahmini 0,765 ile K-en Yakın Komşu algoritması yapmışken en iyi sonucu 0,987 ile Yapay Sinir Ağları elde etmiştir.

Tablo 1. Modellerin Doğruluk Değerleri

Yöntemler	Doğruluk(Accuracy)
K-en Yakın Komşu	0,765
Destek Vektör Makinaları	0,825
Karar Ağacı	0,953
Gaus Naive Bayes	0,778
Yapay Sinir Ağları	0,987



Şekil 1. Veri Seti üzerinde Test Edilen Algoritmaların Karşılaştırılması

Şekil 1' de kullanılan veri seti üzerinde test edilen algoritmaların hata matrisine (confusion matrix) ait doğruluk, kesinlik, hatırlama ve f1 skoru gibi sonuçlar ışığında karşılaştırılmıştır. Karşılaştırma sonuçlarına göre en kötü f1 skoru 0,409 ile destek vektör makinalarına ait olup en iyi f1 skoru 0,966 ile yapay sinir ağı elde etmiştir.

5. Sonuç ve Öneriler

Travma sonrası stres bozukluğu kişilerin ister kendilerinin yaşadığı isterse başkalarının yaşadığı travmatik olaylar sonrasında kişinin hayatını olumsuz etkileyen mental bir hastalıktır. Fiziksel ve ruhsal yaşantıları önemli ölçüde etkilenme olasılığı kuvvetli olan TSSB hastaları gereken tedaviyi almadıklarında intihara varan eğilimler gösterebilir. Yaptığımız çalışma kişilerin TSSB belirtilerini göstermeye başladığı andan itibaren hastalığın erken aşamada tespit edilmesi için katkıda bulunmaktadır. Bunun için yapay zeka algoritmaları ile 741 kişiden toplanan veriler üzerinde analizler yapılmıştır. Yapılan analizler ışığında yapay sinir ağı doğrusal olmayan veriler üzerinde daha başarılı sonuçlar elde ettiği gözlenmiştir. Gelecek çalışmada TSSB taramasına giren hastalar için açık uçlu sorulara verdiği metinler üzerinden analizler yapılacak ve TSSB tahmin oranları artırılmaya çalışılacaktır.

Yazar(lar)ın Katkıları

Yazarlar makalenin son halini okudu ve onayladı.

Çıkar Çatışması

Yazarlar, çıkar çatışması olmadığını beyan eder.

Kaynaklar

- [1]. Association A. P. et al., Diagnostic and statistical manual of mental disorders (DSM-5®), American Psychiatric Pub, 2013.
- [2]. Thabet A. A. M., Y. Abed and P. Vostanis, Comorbidity of PTSD and depression among refugee children during war conflict, *Journal of Child Psychology and Psychiatry*, 2004, 45(3), 533-542.
- [3]. McLaughlin A., Koenen K. C., Hill E. D., Petukhova M., Sampson N. A., Zaslavsky A. M., et al., Trauma exposure and posttraumatic stress disorder in a national sample of adolescents, *Journal of the American Academy of Child & Adolescent Psychiatry*, 2013, 52 (8), 815-830.
- [4]. Jones C., Griffiths R. D., Humphris G. and Skirrow P. M., Memory delusions and the development of acute posttraumatic stress disorder-related symptoms after intensive care, *Critical Care Medicine*, 2001 29(3), 573-580.
- [5]. Li Y. Liu P., Cai Q., Guo J., Zhou Z., Yan H., et al., Posttraumatic stress disorder and mobile health: App investigation and scoping literature review, *JMIR mHealth and uHealth*, 2017 5(10), e156.
- [6]. Weathers F. W., Bovin M. J., Lee D. J., Sloan D. M., Schnurr P. P., Kaloupek D. G., et al., The clinician-administered PTSD scale for DSM-5 (CAPS-5): Development and initial psychometric evaluation in military veterans, *Psychological Assessment*, 30(3), 383-395.
- [7]. Hahn, T., Nierenberg, A. A., & Whitfield-Gabrieli, S. Predictive analytics in mental health: applications, guidelines, challenges and perspectives. *Molecular psychiatry*, 22(1), 37-43.

- [8]. Marinić, I., Supek, F., Kovačić, Z., Rukavina, L., Jendričko, T., & Kozarić-Kovačić, D. Posttraumatic stress disorder: diagnostic data analysis by data mining methodology. *Croatian medical journal*, 48(2.), 185-197.
- [9]. Kessler, R. C., Rose, S., Koenen, K. C., Karam, E. G., Stang, P. E., Stein, D. J., ... & Carmen Viana, M. How well can post-traumatic stress disorder be predicted from pre-trauma risk factors? An exploratory study in the WHO World Mental Health Surveys. *World Psychiatry*, 2014, 13(3), 265-274.
- [10]. Köbach, A., Nandi, C., Crombach, A., Bambonyé, M., Westner, B., & Elbert, T. Violent offending promotes appetitive aggression rather than Posttraumatic stress—A replication study with Burundian ex-combatants. *Frontiers in psychology*, 2015, 6, 1755.
- [11]. Karstoft, K. I., Statnikov, A., Andersen, S. B., Madsen, T., & Galatzer-Levy, I. R. Early identification of posttraumatic stress following military deployment: Application of machine learning methods to a prospective study of Danish soldiers. *Journal of affective disorders*, 2015, 184: 170-175.
- [12]. Reece, A. G., Reagan, A. J., Lix, K. L., Dodds, P. S., Danforth, C. M., & Langer, E. J. Forecasting the onset and course of mental illness with Twitter data. *Scientific reports*, 2017, 7(1): 1-11.
- [13]. He, Q., Veldkamp, B. P., Glas, C. A., & de Vries, T. Automated assessment of patients' self-narratives for posttraumatic stress disorder screening using natural language processing and text mining. *Assessment*, 2017, 24(2): 157-172.
- [14]. Gradus, J. L., King, M. W., Galatzer-Levy, I., & Street, A. E. Gender differences in machine learning models of trauma and suicidal ideation in veterans of the Iraq and Afghanistan Wars. *Journal of traumatic stress*, 2017, 30(4): 362-371.
- [15]. Augsburger, M., & Elbert, T. When do traumatic experiences alter risk-taking behavior A machine learning analysis of reports from refugees. *PLoS one*, 2017, 12(5): e0177617.
- [16]. Leightley, D., Williamson, V., Darby, J., & Fear, N. T. Identifying probable post-traumatic stress disorder: applying supervised machine learning to data from a UK military cohort. *Journal of Mental Health*, 2019, 28(1): 34-41.
- [17]. Spitzer RL, Kroenke K, Williams JB, Löwe B. A brief measure for assessing generalized anxiety disorder: the GAD-7. *Arch Intern Med*. 2006 May 22;166(10):1092–7. pmid:16717171
- [18]. Prins A, Bovin MJ, Smolenski DJ, Marx BP, Kimerling R, Jenkins-Guarnieri MA, et al. The Primary Care PTSD Screen for DSM-5 (PC-PTSD-5): Development and evaluation within a veteran primary care sample. *J Gen Intern Med*. 2016;31(10):1206–1211. pmid:27170304
- [19]. Lee, C. M., Juarez, M., Rae, G., Jones, L., Rodriguez, R. M., Davis, J. A., ... & Harries, A. J. Anxiety, PTSD, and stressors in medical students during the initial peak of the COVID-19 pandemic. *PloS one*, 2021, 16(7): e0255013.
- [20]. Cover, T., & Hart, P. Nearest neighbor pattern classification. *IEEE transactions on information theory*, 1967, 13(1): 21-27.
- [21]. Boser, B. E., Guyon, I. M., & Vapnik, V. N. A training algorithm for optimal margin classifiers. In *Proceedings of the fifth annual workshop on Computational learning theory 1992*, 144-152
- [22]. Badulescu, L. A. (2007). Attribute selection measure in decision tree growing.
- [23]. John, G. H., & Langley, P. (2013). Estimating continuous distributions in Bayesian classifiers. *arXiv preprint arXiv:1302.4964*.