

Makine Öğrenmesi Yöntemi ile Karaciğerde Oluşan Hastalıkların Tahmini

Prediction of Liver Diseases with Machine Learning Method

Mustafa TEKE

Çankırı Karatekin Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, Çankırı

Doi: 10.51764/smutgd.1106793

Geliş Tarihi :21.04.2022

Kabul Tarihi :08.06.2022

ÖZET

Bu çalışmada karaciğer test sonuçlarının makine öğrenmesi algoritmalarından lojistik regresyon sınıflandırılmasına dayalı hastalık tahmin modeli çalışması yapılmıştır. Karaciğer insan vücudunda adeta bir fabrika gibi çalışmaktadır. Bu organın hastalanması bütün vücuda zarar veren birçok etki meydana getirmektedir. Bu çalışmada belirli ölçütlere ve parametrelere göre bu hayati organ için hastalık tahmin modeli gerçekleştirilmiştir. Çalışmada karaciğere ait protein, albümin ve bilirubin gibi değerler hastalık tahmin modelinde incelenmiştir. Çalışmada kullanılan veri modeli açık kaynaklı kaggle web sitesinden alınmıştır. Tahmin modeli python dili ile jupyter notebook ortamında gerçekleştirilmiştir. Kategorik veri tahmini içinse lojistik regresyon modeli tercih edilmiştir. Oluşturulan model %84 doğruluk içermiştir. Değerlendirme ölçütü olarak karmaşıklık matrisi kullanılmış ve çalışmada sunulmuştur.

Anahtar Kelimeler: Makine öğrenmesi, Lojistik regresyon, Karaciğer hastalığı.

ABSTRACT

In this study, a disease prediction model study based on the logistic regression classification of liver test results from machine learning algorithms was performed. The liver works like a factory in the human body. Disease of this organ causes many effects that harm the whole body. In this study, the disease prediction model for this vital organ was performed according to certain criteria and parameters. In the study, values such as protein, albumin and bilirubin belonging to the liver were examined in the disease prediction model. The data model used in the study was taken from the open source kaggle website. The prediction model was implemented in the jupyter notebook environment with python language. Logistic regression model was preferred for categorical data estimation. The model created contained 84% accuracy. Confusion matrix calculation table was used as evaluation criterion and presented in the study.

Keywords: Machine learning, Logistic regression, Liver disease.

1. GİRİŞ

Makine öğrenmesi metotlarının sağlık alanında kullanılmaya başlamasıyla beraber birçok hastalığa tanı koyma metodu zaman içinde geliştirilmiştir. Derin Öğrenme, yapay sinir ağları adı verilen beyin yapısı ve işlevinden esinlenen algoritmalarla ilgili bir makine öğrenimi alt alanıdır (Roy vd. 2020; Khalifa vd. 2020). Bu alanda, Evrişimli Sinir Ağları, Tekrarlayan Sinir Ağları, LSTM'ler, Transformatörler gibi sinir ağı mimarileri çalışılmış ve Dropout, BatchNorm, Xavier / He başlatma ve daha fazlası gibi stratejilerle bunları nasıl daha iyi hale getirilebileceği üzerinde araştırmalar yapılmıştır (Kaur vd. 2020). Python ve TensorFlow kullanarak bu teorik kavramlara ve bunların endüstri uygulamalarına hâkim olunabilmektedir (Yao vd. 2020). Otonom sürüş, işaret dili okuma, müzik üretimi, bilgisayarla görme, konuşma tanıma ve doğal dil işleme gibi gerçek dünya vaka çalışmalarının önü makine öğrenmesi alt alanı olan derin öğrenme sayesinde açılmıştır (Guo vd. 2019). Sağlık hizmetlerinde makine öğrenme uygulamaları, tıbbi görüntüleme çözümlerinde, hasta belirti kalıpları tanımlayabilen sohbet robotlarında, belirli kanser türlerini tanımlayabilen derin öğrenme algoritmalarında ve nadir hastalıkları veya belirli patoloji türlerini tanımlamak için derin öğrenmeyi kullanan görüntüleme çözümlerinde zaten görülmüştür. Derin öğrenme, tıp uzmanlarına sorunları erkenden tespit etmelerine ve böylece çok daha kişiselleştirilmiş ve ilgili hasta bakımı sunmalarına olanak tanıyan iç görüler sağlamada temel bir rol oynamaktadır (Byra vd. 2020). YSA'lar, tıbbi görüntüleme gibi çeşitli kaynaklardan büyük miktarda veriyi işleyerek doktorların bilgileri analiz etmesine ve birden çok durumu tespit etmesine yardımcı olabilir (Yamakawa vd. 2019). Başlıca sağlık uygulamaları; kan örneklerini analizi, diyabetik hastalarda glikoz seviyelerini takibi, kalp rahatsızlıkları tespiti, tümörlerin tespiti, görüntü analizini kullanılarak kanserli hücreleri tespit etmek ve kanseri teşhis etmek ek olarak da ileri seviye küçük mikroorganizma takibinde kullanılmaktadır (Li vd. 2018).

Karaciğerde oluşan hastalıkların ilk evrelerinde herhangi bir belirtisi ortaya çıkmaz iken sonraki zamanlarda belirtiler belirgin bir şekilde ortaya çıkmaktadır (Lin ve Chuang, 2010). Karaciğerde meydana gelen hastalıkların tanısında kan içerisinde bulunan enzim düzeyleri ölçüm sonuçlarına bakılarak karar verilir (Parkin vd. 2005). Makine öğrenimi yoluyla teşhis, durumun varlığını veya türünü gösteren kalıpları görsel olarak tanımlayabilmek için hâlihazırda klinisyene güvendiğimiz alanlarda fizyolojik verilere dayalı bir sınıflandırma görevine indirildiğinde işe yarar (Arjmand vd. 2019). Makine öğrenmesi ile hızlı tanı koyma ve operatör hatalarına izin vermeyen bir teşhis sistemi geliştirilebilmektedir. Bu yönde literatürde Destek Vektör Makinası yöntemi ile karaciğer kimyasal verileriyle sınıflandırma, Naive Bayes ile Destek Vektör Makinası sınıflandırmalarının karşılaştırılması ve hibrit modellerin kullanılması gibi çalışmalar mevcuttur (Schiff vd. 2011; Sorich vd. 2003). Makine öğrenmesi algoritmalarından Bayes sınıflandırıcı ile yapay sinir ağı ile yapılan hastalık teşhisinde yapay sinir ağı sınıflandırmada Bayes sınıflandırıcısından daha iyi sonuç vermiştir (Dandil.,2013). Karaciğer hastalığı veri setini WEKA makine öğrenmesi ara yüzü yardımıyla Random Forest ve J48 algoritmaları da dahil olmak üzere farklı sınıflandırıcılar ile özellik seçimi işlemi gerçekleştirildi. Özellik seçimi işleminden sonra J48 sınıflandırma algoritmasının başarımları %70,6 değerini verirken sınıflandırıcılar içinde en yüksek değeri veren Random Forest algoritması ve başarımları ise %71.8 olarak kaydedilmiştir (Gulia vd., 2014). Alkuşak ve Gök iki farklı karaciğer veri seti üzerinde karaciğer yetmezliği hastalığını YSA, Fonksiyonel Ağaç, RF ve Radial Based Functional metotlarını kullanarak hasta teşhisinde bulunmuşlardır. YSA'yı MATLAB makine öğrenmesi aracını kullanarak diğer metotları da makine öğrenmesi aracı olan WEKA ile çalışmışlardır. Çalışmalarının sonucunda WEKA ve Matlab araçlarının çıktıkları iki ayrı veri seti için %76, ve %78 değerinde olmuştur. Keleş ve arkadaşları ILPD karaciğer veri seti ile karaciğer yetmezliği için Decision Stump, J48, REP Tree, Lojistik Model Ağacı (LMT), Hoeffding Tree, RF, IBk ve RT modellerini veri setine uygulamışlar ve en yüksek %81.9 başarımları gösteren algoritma RF modelinin olduğu gözlenmiştir. Kan değerlerinden alınan değerlerin dışında tıbbi görüntülerden de karaciğer hastalığı teşhisi yapılmakta ve bu alanda Derin öğrenme ile de çalışılmaktadır. Derin öğrenme, şimdiye kadar segmentasyon, nesne (yani lezyon veya ilgi bölgesi) algılama ve sınıflandırmayı içeren çeşitli görüntüleme görevlerini gerçekleştirmek için bir dizi sinir ağı mimarisini kullanan yeni ve güçlü bir makine öğrenme yöntemidir (Bayet vd.2020). Derin öğrenme yöntemleri, geleneksel makine öğrenme yöntemlerinden (yani destek vektör makinesi (SVM) ve rastgele orman (RF)) bir anlamda farklıdır. İkincisi, algoritmayı eğitmek için özellik çıkarma yöntemlerine güvenirken derin öğrenme yöntemleri görüntüyü öğrenir; veriler özellik çıkarmaya gerek kalmadan doğrudan giriş verisinin eğitilmesiyle sağlanır (Tai, Lo, 2018).

Bu çalışmada ise karaciğer analiz sonuçlarından elde edilen değerler cinsiyet, yaş ve diğer parametreler kullanılarak sınıflandırılmış ve sınır dışı değerler tespit edilerek karaciğerde hastalık var ya da yok şeklinde tahmin uygulaması gerçekleştirilmiştir.

Çalışmanın devamında materyal ve metot kısmı açıklanarak veri seti hakkında bilgi verilmiştir ve makine öğrenmesi algoritması çalıştırılarak başarımlar ölçümleri ile sonuç grafikleri çalışmanın sonunda sunulmuştur. Uygulamada kategorik veri sınıflandırılmasında kullanılan makine öğrenmesi algoritmalarından olan lojistik regresyon modeli oluşturulmuş ve elde edilen sonuçlar, detaylı analiz grafikleri çalışmada verilmiştir.

2. MATERYAL VE METOT

İnsan vücudunda karaciğerin görev yoğunluğu diğer organların görev yoğunluğundan daha fazla olup kütle ve hacim olarak en büyük ve en önemli organımız olmaktadır. Karaciğerde oluşan sorunların farkına varılmasında karaciğerin ürettiği enzimler önemli bir vazife üstlenmektedir. Bu nedenle çalışmada karaciğer enzim değerlerine bakılarak açık erişim bir veri seti üzerinde çalışılmıştır. Gerçekleştirilen makine öğrenmesi çalışmasında açık kaynak erişimli karaciğer hastalarından teşhis edilmiş toplanan veri seti kullanılmıştır. Mevcut veri içerisinde 10 farklı öznitelik ile kategorik sınıf bilgisini barındırmaktadır. Metodoloji kısmında ise kategorik verileri sınıflandırmada yüksek doğruluk veren Lojistik regresyon algoritmasından faydalanılmıştır. Yine açık kaynak erişimli Python makine öğrenmesi kütüphanelerinden faydalanılmıştır. Kullanılan açık kaynak erişimli veri kümesinin kolay anlaşılır olmasını sağlayan dağılım grafikleri çalışmada detaylı bir şekilde verilmektedir.

2.1 Veri Seti ve Veri Ön İşleme

Karaciğer hasta ve hasta değil şeklinde kategorik olarak sınıflandırılmış veri seti kaggle sitesinden alınmıştır (URL-4, 2021). Kullanılan veri yığınının öznitelik olarak yaş, cinsiyet, toplam bilirubin, doğrudan bilirubin, toplam protein, albümin, alkalik fosfat, alamin aminotransferaz, aspartat aminotransferaz ve albümin/globülin oranı değerleri bulunmaktadır. Sınıf değerleri hasta (1) sağlıklı (2) şeklinde kategorik olarak ayrılmıştır. Kullanılan veri seti, içerisinde 1166 hastadan alınmış 10 farklı öznitelik ölçüm değerlerinin yanı sıra iki sınıf bilgisini içeren tablo şeklindedir.

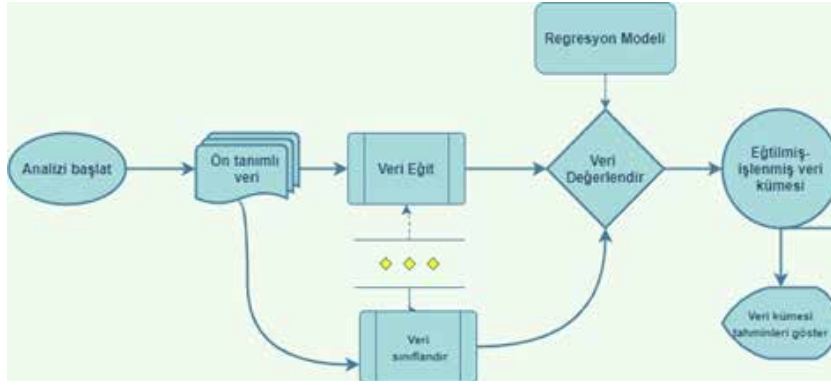
Kullanılan veri seti içerisinde eksik ölçümler bulunmaktadır. Eksik verilerin yerlerini doldurmak için farklı yöntemler icra edilmektedir. Genellikle eksik verinin bulunduğu satır öznitelik sütununun ortalaması, medyanı ya da regresyon analizi yapılarak doldurulmaktadır. Çalışmada eksik veriler öznitelik değerinin ortalama değeri olarak tamamlanmıştır. Bunun yanında makine öğrenmesi algoritmasında öznitelik değerleri 0-1 aralığına çekilerek her bir özelliğin sayısal değeri eş öneme sahip olacak şekilde getirilmiştir. Çalışmada kullanılan veri setine ait örnek tablo 1'de sunulmuştur.

Tablo 1. Çalışmada kullanılan veri seti örneği

Yaş	Cinsiyet	Toplam Bilirubin	Doğrudan Bilirubin	Alkalik Fosfat	Alamin Aminotransferaz	Aspartat Aminotransferaz	Toplam Protein	Albumin	Veri
65	Bayan	0,70	0,10	187,00	16,00	18,10	6,80	3,30	1,00
68	Erkek	10,90	5,50	699,00	64,00	9,40	7,50	3,20	1,00
62	Erkek	7,30	4,10	490,00	60,00	68,00	7,00	3,20	1,00
58	Bayan	1,00	0,40	182,00	14,00	20,10	6,80	3,20	1,00
72	Erkek	3,90	2,00	195,00	27,00	28,20	7,30	3,40	1,00
46	Erkek	1,80	0,70	208,00	19,00	14,10	7,60	6,40	1,00

2.2 Lojistik Regresyon Modeli

Lojistik Regresyon kategorik sınıflandırma sorunlarını çözmekte kullanılan istatistiksel bir metot olup gözetimli makine öğrenmesi algoritmalarındandır (Özdemir E. Ballı S., 2020). Kullanılacak veri seti kümesinin lojistik regresyon analizinin yapılması ikili ihtimali (0 ya da 1) verir. Çalışmada kullanılan veri değeri bağımlı değişken olup sayısal olarak (1-karaciğer hastası 2- karaciğer hastası değil) şeklinde ifade edilmektedir. Şekil 1'de çalışmada kullanılan regresyon modeli akış şeması görülmektedir.

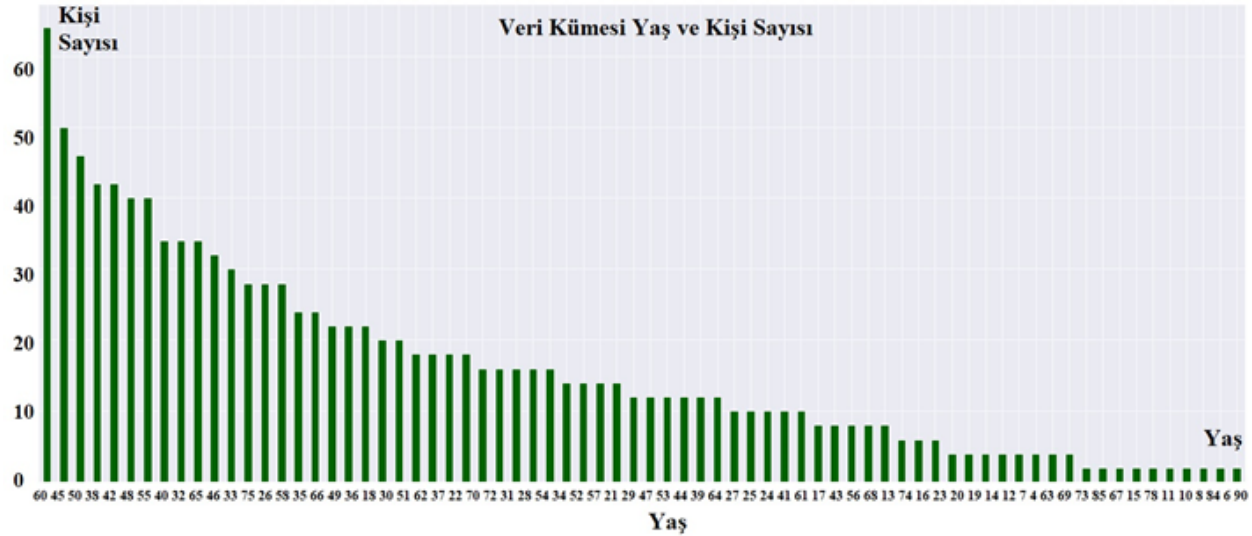


Şekil 1. Çalışmada kullanılan regresyon modeli

Lojistik regresyon, bağımlı değişken ikili olduğunda yapılacak en uygun regresyon analizidir. Diğer regresyon analizleri gibi lojistik regresyon tahmin edici yapıya sahip bir analizdir. Lojistik regresyon, verileri tanımlamak ve bir bağımlı ikili değişken ile bir veya daha fazla yazılı, sıra, aralık veya oran düzeyinde bağımsız değişken arasındaki ilişkiyi açıklamak için kullanılır. Bağımlı değişken, doğası gereği ikiye bölünmüş olmalıdır (örneğin, Erkek karşı Bayan). Sürekli yordayıcılar standart puanlara dönüştürülerek ve -3.29'un altındaki veya +3.29'dan büyük değerler kaldırılarak değerlendirilebilecek verilerde aykırı değerler olmamalıdır (Trivizakis vd. 2019; Jyoti vd. 2020). Yordayıcılar arasında yüksek korelasyon (çoklu bağlantı) olmamalıdır. Bu, yordayıcılar arasındaki bir korelasyon matrisi ile değerlendirilebilir. Tabachnick ve Fidell (2013), bağımsız değişkenler arasındaki uzun korelasyon katsayılarının 0,90'dan küçük olması nedeniyle varsayımın karşılandığını öne sürmektedir (Liu, Abdukeyim, Yan, 2019). Lojistik regresyon analizinin merkezinde bir olayın logaritmik olasılıklarını tahmin eden görev vardır. Matematiksel olarak lojistik regresyon, eşitlik bir de tanımlanan çoklu doğrusal regresyon fonksiyonunu tahmin eder (Reddy vd. 2018).

$$f = \frac{e^{(n_0 + (n_1 * x))}}{1 + e^{(n_0 + (n_1 * x))}} \quad (1)$$

Burada eşitlik 1`de, f tahmin edilen çıktı, n0 önyargı veya kesme terimidir, n1 tek giriş değeri ve x katsayıdır. Giriş verilerindeki her sütunun, eğitim verilerinden öğrenmesi gereken ilişkili bir n katsayısı (sabit bir gerçek değer) vardır.



Şekil 2. Veri kümesi yaş ve kişi sayısı dağılımları

Şekil 2`de veri setinden elde edilmiş veri kümesindeki yaş ve kişi sayıları grafiği gösterilmektedir. Örneğin şekil 2 incelendiğinde veri setinde cinsiyet ayrımı gözetilmeksizin 60 yaşında 60`ın üzerinde kişi varken 30 yaşında 20 kişi vardır. Her yaşa karşılık veri setinde bulunan kişi sayısı net bir biçimde görülmektedir.


3. TAHMİN VE ANALİZ SONUÇLARI

Çalışmada yaş, cinsiyet, toplam bilirubin, doğrudan bilirubin, toplam protein, albümin, alkalın poshpoataz, alamin aminotransferaz, aspartat aminotransferaz ve albümin/globülin oranı değerleri sınıflandırması şekil üç içinde yapılmıştır. Burada yapılan çalışmada her bir parametrenin bir başka parametreye göre dağılımlarının verildiği grafik şekil üçte görülebilmektedir. Örneğin yaş guruplarına göre toplam bilirubin, doğrudan bilirubin, toplam protein, albümin, alkalın poshpoataz, alamin aminotransferaz, aspartat aminotransferaz ve albümin/globülin oranı değerleri veya cinsiyete göre toplam bilirubin, doğrudan bilirubin, toplam protein, albümin, alkalın poshpoataz, alamin aminotransferaz, aspartat aminotransferaz ve albümin/globülin oranı değerleri şekil üç üzerinde görülebilmektedir.

Bazı parametreler diğer parametrelere göre özel öneme sahiptir. Çünkü bunların önceden bilindiği şekilde belirli bir sayısal değer üstünde olmaları ilgili organda ileride olabilecek bir hastalığın öncü bilgisini saklamaktadır. Bu durumdan yararlanılarak belirli değerlere göre hastalık teşhisi yapmak daha da kolaylaşmaktadır. Örneğin kanda en fazla bulunan plazma proteini olan albumin, karaciğer tarafından sentezlenir. Kılcal damarlardan geçemeyecek kadar büyük proteinlerin oluşturduğu onkotik basınç sayesinde proteinlerin bu bölgelerden geçişini sağlar. Böylece ödem oluşumunu ve damar yatağında sıvı birikimi sonucu oluşabilen tansiyon yüksekliğini engeller. Albumin seviyesi, yapılan laboratuvar testleri ile kan ve idrardan olmak üzere iki farklı şekilde ölçülebilir. Albumin referans aralığı Kan düzeyinde yetişkinlerde 3.4 ile 5.4 g/dL iken, idrarda normal albumin değeri 0 ile 8 mg/dL'dir (URL-1, 2021). Ya da Bilirubin, vücudun kırmızı kan hücrelerini parçalama işlemi sırasında ortaya çıkan sarımsı bir maddedir. Bu madde karaciğerde bulunur ve normal olarak sindirim sırasında vücuttan dışarı atılır. Karaciğerin hasar görmesi durumunda bilirubin kan ve idrara sızabilir. İdrarda bilirubin, karaciğer hastalığının bir belirtisi olabilir (URL-2, 2021). Bunun gibi önceden bilinen sınırlar dâhilinde derin öğrenme ile yüksek doğrulukta tahminler yapılabilmektedir. Burada derin öğrenmede eğitilen verinin gerçek örneklerle dayanması ve ayrıntı içermesi sonuçların güvenilirliğini arttırmaktadır. Bu güvenilirlik ve doğruluk karmaşık matrisi ile hesaplanabilmektedir.

Aspartat aminotransferaz (AST) referans aralığı ya da farklı bir deyişle normal değerleri, kadınlarda 15 ile 42 IU/L iken erkeklerde 15 ile 20 IU/L düzeyindedir. Alamin aminotransferaz (ALT) sağlıklı erkek bireylerde kandaki seviyesi 10-40 U/L, kadınlarda ise 7-35 U/L aralığında olmalıdır (URL-3, 2021). Kullanılan veri setinde erkek bireylerin hasta sınıf değeri kadın bireylerden daha fazladır. Genelde bu parametrelerin ilgili cinsiyete göre belirlenmiş referans aralık değerlerinden yüksek çıkması durumunda karaciğer ile ilgili bir hastalığın habercisi olmaktadır. Çoğu karaciğer hastalığı tipinde, ALT seviyesi AST'den yüksektir ve AST / ALT oranı düşük olacaktır (1'den az). Birkaç istisna var; AST / ALT oranı genellikle Alkolik Hepatitte, Sirozda ve Akut Hepatitte veya safra kanalı tıkanıklığından kaynaklanan yaralanmanın ilk veya iki gününde artar. Kalp veya kas hasarında AST genellikle ALT' den çok daha yüksektir (genellikle 3-5 kat daha yüksektir) ve seviyeler, karaciğer hasarına göre ALT' den daha uzun süre daha yüksek kalma eğilimindedir. Bu enzimlerdeki değişimlerin sınıflandırılması ile birçok hastalık elenebilmekte ve geriye kalanlar için doğruya en yakın sonuç tasarlanan model ile tahmin edilebilmektedir (Deshmukh vd. 2020; Lou vd. 2020).

Kanda iki çeşit protein mevcuttur, albüminler ve globülinler. Albumin kanda birçok küçük molekülün taşınmasından sorumludur ancak albüminin asıl görevi damarlardaki sıvının damar dışına kaçmasını önlemektir. Globulin proteinleri içerisinde enzimler, antikorlar ve 500'den fazla değişik protein vardır. Albumin ve globulin oranı A/G oranı total protein ve albuminin direkt ölçümlerinden elde edilir (URL-1, 2021). Kandaki toplam protein, albümin ve bilirubin dağılımlarının cinsiyete göre sınıflandırılması şekil 3'de gösterilmektedir.



Şekil 3. Protein, albümin ve bilirubin dağılımlarına göre cinsiyet dağılım grafikleri karşılaştırması
a)Protein alımına göre b) Albümin düzeyine göre c)Toplam bilirubin düzeyine göre

Şekil 3 a'da toplam protein miktarına göre, 3 b'de albümin düzeyine göre ve 3 c'de toplam bilirubin düzeyine göre sınıflandırma yapılmıştır. Her üç grafikte de toplam popülasyonun büyük çoğunluğu erkekler tarafında çıkmıştır. Bunun nedeni veri gurubunu oluşturan toplam 1166 kayıt verisinin 882 sinin erkek bireylerden oluşturulmuş olmasıdır. Bu sınıflandırmadan veri setindeki erkek hastalar içinde karaciğer hastalığı görülme riski çok daha fazla olacaktır.

Şekil 4`te özniteliklerin birbirleri ile olan korelasyon ilişkisinin grafiği verilmiştir. Korelasyon değeri 0.90 altından olduğu için bütün öznitelikler sınıflandırma algoritması içerisinde koşturulmuştur. Şekil 4 kullanılarak öznitelik sayısında eksiltme yapıp yapılmayacağı yani öznitelikler arasındaki benzerlik ilişkisine bakılmaktadır. Öznitelikler arasında ilişkisi yüksek olan özellikler algoritmaya alınmayarak sistemin hesaplamasında hız ve doğruluk oranında artma olacağından şekil 4 bizim için öznitelik ayırt etme aracı olarak da kullanılmaktadır.



Şekil 4. Regresyon modeline göre hastalık tahmin grafiği

Amaçlanan model, eğitim doğruluğu %87, test doğruluğu %84, hassasiyet %89 F1 0.78 ve geri çağırma %76 sağlamıştır. P kesinlik, R geri çağırma, ACC doğruluktur, F1 Kesinlik ve geri çağırma değerlerinin harmonik ortalamasını gösterir. Eşitlik 2'de sırasıyla TP gerçek pozitif, TN gerçek negatif, FP yanlış pozitif ve FN yanlış negatiftir. Tablo 2' de karmaşıklık matrisi sonucu sunulmuştur.

$$P = \frac{TP}{TP+FP} \quad , \quad R = \frac{TP}{TP+FN} \quad , \quad ACC = \frac{TP}{TP+FP+TN+FN} \quad , \quad F_1 = 2 * \frac{P*R}{P+R} \quad (2)$$

Tablo 2. Karmaşıklık matrisi sonucu

Tahmin \ Gerçek	Pozitif	Negatif
Pozitif	748	84
Negatif	100	234

Doğruluk, bir modelin başarısını ölçmek için yaygın olarak kullanılan bir ölçümdür. Hassasiyet, pozitif olarak tahmin ettiğimiz değerlerden kaçının aslında pozitif olduğunu gösteren bir değerdir ve hassasiyet (Geri Çağırma), operasyonların ne kadarına ihtiyacımız olduğunu gösteren bir ölçümdür. Pozitif olarak tahmin etmek. Basit bir ortalama yerine harmonik bir ortalama olmasının nedeni, aşırı durumları göz ardı etmememiz gerektiğidir.

Şekil 4`te görülebileceği üzere tüm parametrelerin yer aldığı bir dağılım elde edilmiştir. Hastalık 0 ile 1 arasında ölçeklendirilmiştir. 1 hasta 0 hasta değil demektir. Tüm parametrelere göre bir puanlandırma ile 0 ile 1 arasında veriler sınıflandırılmıştır. Doğrudan bilirubin değeri en yüksek olanlar dağılım grafiğinde 0,87'lik bir puan ile hastalığa en yakın grup olmuştur.

4. SONUÇLAR

Bu çalışmada makine öğrenmesi tabanlı lojistik regresyon sınıflandırma modeli kullanılarak belirli şartlar altında karaciğer test sonuçlarının belirli bir teknikle sınıflandırılmasına dayalı hastalık tahmin modeli çalışması yapılmıştır. Karaciğer hastalıkları veri seti açık kaynak erişimli ve hazır olarak kullanılmıştır. Sınıflandırma modeli olarak lojistik regresyon modeli tercih edilmiştir. Daha önceden bilinen ve sağlıklı bireylerde olması gereken aralığın dışındaki değerlere sahip bireyler yaşlarına ve cinsiyetlerine göre sınıflandırılmış ve hastalık tahmin modeli gerçekleştirilmiştir.

Çalışma sonunda uygulanan modelde eğitim doğruluğu % 87, test doğruluğu % 84, hassasiyet % 89 F1 0.78 ve geri çağırma % 81 olarak çıkmıştır. Modelde kullanılan tüm parametreler analizin bir parçası olarak grafik halinde sınıflandırılmıştır. Elde edilen bu sınıflandırma grafikleri çalışma içerisinde sunulmuştur. Modelin etkinliğini ölçmek için uluslararası kabul görmüş olan karmaşıklık matrisi kullanılmış ve çalışma içinde elde edilen sonuçlar sunulmuştur. Uygulanan modelin daha çok veri içerecek şekilde daha büyük verilere uygulanması durumunda daha büyük doğruluk elde etmek mümkün olabilecektir.

5. KAYNAKLAR

- Roy, S., Menapace, W., Oei, S., Luijten, B., Fini, E., Saltori, C., & Demi, L. Deep learning for classification and localization of COVID-19 markers in point-of-care lung ultrasound. *IEEE transactions on medical imaging*, (2020) 39(8), 2676-2687.
- Khalifa, NEM., Taha, MHN., Ali, DE., Slowik, A., & Hassanien, AE. Artificial intelligence technique for gene expression by tumor RNA-Seq data: a novel optimized deep learning approach. *IEEE*, (2020); 8, 22874-22883.
- Kaur, S., Singla, J., Nkenyereye, L., Jha, S., Prashar, D., Joshi, G. P., & Islam, SR. Medical diagnostic systems using artificial intelligence (ai) algorithms: Principles and perspectives. *IEEE* (2020); 8, 228049-228069.
- Yao, Z., Li, J., Guan, Z., Ye, Y., & Chen, Y. Liver disease screening based on densely connected deep neural networks. *Neural Networks*, (2020); 123, 299-304.
- Guo, X., Wang, F., Teodoro, G., Farris, A. B., & Kong, J.. Liver steatosis segmentation with deep learning methods. In 2019 IEEE 16th International Symposium on Biomedical Imaging (2019); (pp. 24-27). IEEE.
- Byra, M., Styczynski, G., Szmigielski, C., Kalinowski, P., Michalowski, L., Paluszkiwicz, R., & Nowicki, A. Adversarial attacks on deep learning models for fatty liver disease classification by modification of ultrasound image reconstruction method. In 2020 IEEE International Ultrasonics Symposium (IUS) (2020, September); (pp. 1-4). IEEE.
- Yamakawa, M., Shiina, T., Nishida, N., & Kudo, M. Computer aided diagnosis system developed for ultrasound diagnosis of liver lesions using deep learning. In 2019 IEEE International Ultrasonics Symposium (IUS) . (2019, October); (pp. 2330-2333). IEEE.
- Li, Y., He, Q., & Luo, J. A deep learning trial on transient elastography for assessment of liver fibrosis. In 2018 IEEE International Ultrasonics Symposium (IUS) (2018, October); (pp. 1-4). IEEE.
- Arjmand, A., Angelis, CT., Tzallas, AT., Tsiouras, MG., Glavas, E., Forlano, R., & Giannakeas, N. Deep learning in liver biopsies using convolutional neural networks. In 2019 42nd International Conference on Telecommunications and Signal Processing (TSP) (2019, July); (pp. 496-499). IEEE.
- Alkuşak E. ve Gök M., 2015. "Karaciğer Yetmezliğinin Teşhisinde Makine Öğrenmesi Algoritmalarının Kullanımı", ISITES 2014 Sempozyumu (ISITES'2014); 18-20 Haziran 2014; Karabük. 703-707.
- Özdemir E. Ballı S. "Türkiye Erkekler Basketbol Ligi Maç Sonuçlarının Makine Öğrenmesi Yöntemleri ile Tahmini", Mühendislik Bilimleri ve Tasarım Dergisi, 2020; 8 (3): 740 - 752.
- Bayet, J., Hoogenboom, T., Sharma, R., & Angelini, ED. Machine-Learning on Liver Ultrasound to Stratify Multiple Diseases via Blood-Vessels and Perfusion Characteristics. In 2020 IEEE 17th International Symposium on Biomedical Imaging (ISBI) (2020, April); (pp. 1351-1354). IEEE.
- Tai, SK., & Lo, YS. Using deep learning to evaluate the segmentation of liver cell from biopsy image. In 2018 9th International Conference on Awareness Science and Technology (iCAST) 2018; (pp. 232-235). IEEE.
- Trivizakis, E., Manikis, GC., Nikiforaki, K., Drevelegas, K., Constantinides, M., Drevelegas, A., & Marias, K. Extending 2-D convolutional neural networks to 3-D for advancing deep learning cancer classification with application to MRI liver tumor differentiation. *IEEE journal of biomedical and health informatics*, (2018); 23(3), 923-930.

- Jyoti, O., Islam, N., & Hasnain, F. M. S. Prediction of Hepatitis Disease Using Effective Deep Neural Network. In 2020 IEEE International Conference for Innovation in Technology (INOCON) (2020); (pp. 1-5). IEEE.
- Liu, Z., Abdukeyim, N., & Yan, C. Image classification of hepatic echinococcosis based on convolutional neural network. In 2019 6th International Conference on Systems and Informatics (ICSAI) (2019); (pp. 1280-1284). IEEE.
- Lin, R. H., & Chuang, C. L. A hybrid diagnosis model for determining the types of the liver disease. *Computers in Biology and Medicine*, (2010). 40(7), 665-670.
- Schiff, E. R., Maddrey, W. C., & Sorrell, M. F. *Schiff's Diseases of the Liver*. John Wiley & Sons . (2011).
- Parkin, D. M., Bray, F., Ferlay, J., & Pisani, P. *Global cancer statistics, 2002*. CA: a cancer journal for clinicians, (2005). 55(2), 74-108.
- Reddy, DS., Bharath, R., & Rajalakshmi, P. A novel computer-aided diagnosis framework using deep learning for classification of fatty liver disease in ultrasound imaging. In 2018 IEEE 20th International Conference on e-Health Networking, Applications and Services (Healthcom) (2018, September); (pp. 1-5). IEEE.
- Sorich, M. J., Miners, J. O., McKinnon, R. A., Winkler, D. A., Burden, F. R., & Smith, P. A. Comparison of linear and nonlinear classification algorithms for the prediction of drug and chemical metabolism by human UDP-glucuronosyltransferase isoforms. *Journal of chemical information and computer sciences*, . (2003) 43(6), 2019-2024.
- Dandil, E. Karaciğerde Oluşan Hastalıkların Tespitinde Makine Öğrenmesi Yöntemlerinin Kullanılması XV. Akademik Bilişim Konferansı syf 614-617. 23-25 Ocak 2013.
- Gulia, A., Vohra, R., & Rani, P. Liver patient classification using intelligent techniques. *International Journal of Computer Science and Information Technologies*, (2014). 5(4), 5110-5115.
- Deshmukh, S., Lokhande, A., Wasnik, R., & Singhal, N. Vacuole segmentation and quantification in liver images of Wistar rat. In 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC) . (2020); (pp. 1396-1399). IEEE.
- Lou, Y., Qian, T., Li, F., Zhou, J., Ji, D., & Cheng, M. Investigating of Disease Name Normalization Using Neural Network and Pre-Training. *IEEE Access*, (2020); 8, 85729-85739.
- URL-1, Albümin. <https://www.medicalpark.com.tr/albumin/hg-2198> (Erişim Tarihi: 11.03.2021)
- URL-2, Bilirubin. <https://www.memorial.com.tr/tani-ve-testler/bilirubin-testi-nedir> (Erişim Tarihi: 11.03.2021)
- URL-3, Aspartat Aminotransferaz. <https://www.medicalpark.com.tr/alt/hg-2178> (Erişim Tarihi: 11.03.2021)
- URL-4, Veri seti. <https://www.kaggle.com/datasets> (Erişim Tarihi: 11.03.2021)