

**TÜRKİYE CUMHURİYETİ
KARADENİZ TEKNİK ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ**

BİYOİSTATİSTİK ve TIP BİLİŞİMİ ANABİLİM DALI

**AKUT APANDİSİT HİBRİT KARAR DESTEK
SİSTEMİ**

Tuğba KURT

YÜKSEK LİSANS TEZİ

Prof. Dr. Kemal TURHAN

TRABZON-2017



**TÜRKİYE CUMHURİYETİ
KARADENİZ TEKNİK ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ**

BİYOİSTATİSTİK ve TIP BİLİŞİMİ ANABİLİM DALI

**AKUT APANDİSİT HİBRİT KARAR DESTEK
SİSTEMİ**

Tuğba KURT

YÜKSEK LİSANS TEZİ

Prof. Dr. Kemal TURHAN

TRABZON-2017

ONAY

Bu tez yüksek lisans tezi standartlarına uygun bulunmuştur.

Prof. Dr. Kemal TURHAN

Biyoistatistik ve Tıp Bilişimi Anabilim Dalı Başkanı

Karadeniz Teknik Üniversitesi Sağlık Bilimleri Enstitüsü Biyoistatistik ve Tıp Bilişimi Anabilim Dalı Yüksek Lisans Öğrencisi Tuğba KURT'un hazırladığı “**Akut Apandisit Hibrit Karar Destek Sistemi**” başlıklı tez KTÜ Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin ilgili maddeleri uyarınca kapsamı ve bilimsel kalite yönünden değerlendirilerek yüksek lisans tezi olarak kabul edilmiştir.

Danışman: Prof. Dr. Kemal TURHAN

Yüksek Lisans/Doktora Sınavı Jüri Üyeleri

Prof. Dr. Kemal TURHAN

Yrd. Doç. Dr. Burçin KURT

Yrd. Doç. Dr. Özlem BİLİR

Tarih:

Bu tez KTÜ Sağlık Bilimleri Enstitüsü Yönetim Kurulunun .../.../.... tarih ve... sayılı kararıyla onaylanmıştır.

Prof. Dr. Ali Osman KILIÇ

Sağlık Bilimleri Enstitüsü Müdürü

BEYAN

Bu tez çalışmasının KTÜ Sağlık Bilimleri Enstitüsü tez yazım kılavuzu standartlarına uygun olarak yazıldığını, tezin akademik ve etik kurallara bağlı kalınarak gerçekleştirilmiş özgün bir bilimsel araştırma eserim olduğunu, tezde yer alan ve bu tez çalışmasıyla elde edilmeyen tüm bilgi ve yorumlara kaynak gösterildiğini ve kaynakların kaynaklar listesinde yer aldığını, tezin çalışılması ve yazımı aşamalarında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

06.06.2017

Tuğba KURT

TEŐEKKÖR

Bu alıřmam süresince bana yol gösteren, beni bu yola girmek için teşvik eden ve yardımlarını esirgemeyen Biyoistatistik ve Tıp Biliřimi Anabilim Dalı Başkanı değerli danışman hocam Prof. Dr. Kemal TURHAN'a, bilgilerinden faydalandığım değerli hocam Yrd. Do. Dr. Burin KURT'a, alıřmanın her aşamasında yanımda olup, bilgisiyle her zaman bana destek olan canım arkadaşım İlknur BUAN KIRKBİR'e ve anlayışı için sevgili eşim Ömür KURT'a, oğluma ve aileme teşekkürlerimi sunarım.

Tuğba KURT

İÇİNDEKİLER

İç kapak Sayfası	Sayfa
ONAY	ii
BEYAN	i
TEŞEKKÜR	i
İÇİNDEKİLER	1
TABLOLAR DİZİNİ	3
ŞEKİLLER DİZİNİ	4
KISALTMA, SİMGE ve FORMÜLLER	5
1. ÖZET	7
2. SUMMARY	9
3. GİRİŞ ve AMAÇ	11
4. GENEL BİLGİLER	13
4.1. Akut Karın Ağrısı	13
4.2. Akut Apandisit.....	14
4.2.1. İnsidans (Sıklık).....	15
4.2.2. Akut Apandisit Tanısı	15
4.2.3. Tedavi	18
4.3. Lojistik Regresyon Analizi	19
4.3.1. Lojistik Regresyon Analizinde Değişken Seçimi	20
4.3.2. Lojistik Regresyon Modelinin Kurulması ve Parametre Tahmin Yöntemleri.....	20
4.3.4. Uyum İyiliği İstatistikleri.....	22
4.4. Makine Öğrenmesi Yaklaşımı	22
4.5.1. Danışmanlı Öğrenme	24
4.5.2. Danışmansız Öğrenme	24
5. GEREÇ ve YÖNTEMLER	25
5.1. Çalışmada Kullanılan Yöntemlerin Detayları.....	25
5.2. İleriye Doğru Seçim Testiyle Geriye Dönük Eleme (Backward Stepwise).....	25
5.3. Destek Vektör Makineleri (DVM).....	26
5.3.1. Doğrusal Ayrılabilen Veriler için DVM	28
5.3.2. Doğrusal Ayrılamayan Veriler için DVM	28

5.4. Verilerin Hazırlanması.....	30
6. BULGULAR.....	31
6.1. Veri Setinin Analizi	31
6.1.1. Uygulamada Kullanılan Değişkenler.....	31
6.2. Lojistik Regresyon Geriye Doğru Adımsal Eleme Modeline Dair Bulgular.....	33
6.3. Destek Vektör Makinesi Modeline Dair Bulgular	38
7. TARTIŞMA ve SONUÇ	42
8. KAYNAKLAR	45
9. ETİK KURUL ONAYI.....	50
10. ÖZGEÇMİŞ	51



TABLÖLAR DİZİNİ

Tablo	Sayfa
Tablo 1. Adımsal seçim metotlarından olabilirlik oran test istatistiğine dayalı geriye doğru eleme yöntemi (backward LR elimination method) kullanılarak elde edilen en uygun çok değişkenli lojistik regresyon modeli	34
Tablo 2. Hosmer ve Lemeshow test sonuçları	35
Tablo 3. İlk sınıflama tablosu	35
Tablo 4. Adımsal sınıflama tablosu	36
Tablo 5. Akut apandisit tanısı alan hastalarda yaş, lökosit, lenfosit, total protein, AST, CRP değişkenlerinin tanımlayıcı istatistikleri ve cinsiyet değişkeninin dağılımı	37
Tablo 6. Akut apandisit tanısı almayan hastalarda yaş, lökosit, lenfosit, total protein, AST, CRP değişkenlerinin tanımlayıcı istatistikleri ve cinsiyet değişkeninin dağılımı	37
Tablo 7. DVM kernel fonksiyonları parametre tablosu	39
Tablo 8. Geliştirilen modellere ait duyarlılık ve özgüllük değerleri	39
Tablo 9. Linear DVM modeli sonuçları ile gerçek sonuçların karşılaştırılması. TP (True Positive), TN (True Negative), FP (False Positive), FN (False Negative)	41

ŞEKİLLER DİZİNİ

Şekil	Sayfa
Şekil 1. Karın Ağrısı Sınıflandırması	14
Şekil 2. Apandisit oluşum süreci ve evreleri	15
Şekil 3. Makine öğrenmesinin aşamaları	23
Şekil 4. Destek vektör makineleri çalışma prensibi	27
Şekil 5. Doğrusal olarak ayrılabilen iki sınıflı sınıflama problemi	28
Şekil 6. Doğrusal olarak ayrılamayan verilerin farklı boyutlardaki uzaylara aktarılması	29
Şekil 7. Train set örneği	38
Şekil 8. Test set örneği	38
Şekil 9. Geliştirilen tanı modellerinin performanslarının karşılaştırması	40

KISALTMA, SİMGE ve FORMÜLLER

Kısaltmalar

AST	Aspartat aminotransferaz
ALT	Alanin aminotransferaz
AUC	Area Under the Curve
BT	Bilgisayarlı Tomografi
BUN	Kan üre azotu
CRP	C-reaktif protein
DVM	Destek Vektör Makinesi
FN	False Negative
FP	False Pozitive
GA	Güven Aralığı
GÖRH	Gastroözofageal Reflü Hastalığı
HCG	Human Koryonik Gonadotropin Hormon
IgA	Immünglobulin A
ICD	International Classification of Diseases
LR	Likelihood Ratio
MR	Manyetik Rezonans
MPV	Trombosit dağılım genişliği
OR	Odss Ratio
PCT	Prokalsitonin
PDW	Trombosit dağılım genişliği
PİH	Pelvik İnflamatuvar Hastalık
ROC	Receiver Operating Characteristic
RTF	Radyal Tabanlı Fonksiyon
SVM	Support Vector Machines
TP	True Pozitive
TN	True Negative
YSA	Yapay Sinir Ağları

Singeler

δ	Delta
σ	Sigma
κ	Kappa
γ	Gamma
χ^2	Ki-kare
β	Beta
π	Pi
ε	Epsilon
φ	Phi



1. ÖZET

Akut Apandisit Hibrit Karar Destek Sistemi

Akut apandisit, apandisin lümeninin tıkanmasına bağlı olarak gelişen bir inflamasyondur. İnflame (iltihaplı) apandisin ameliyatla kesilip çıkarılmasıyla tedavi edilir. Apandisit tanısını koymak zor olabilir. Çünkü hastalığın belirtileri birçok hastalıkta da vardır. Özellikle apandisit yerinin değişken olması tanıyı iyice güçleştirir. Ne yazık ki akut apandisit olan hastaların bazıları, tanı koyulurken geçen süreçte peritonit ya da diğer komplikasyonlardan birine maruz kalabilmektedirler. Bu hastalar, teşhisi zamanında yapılan hastalara göre daha yüksek ölüm oranına sahiptirler. Bu açıdan akut apandisit erken teşhisi, hasta için büyük önem arz etmektedir. Apandisit tanısı için çeşitli yöntemler mevcuttur. Bunlardan biri de makine öğrenmesi yöntemidir.

Makine öğrenmesi, yapay zekâ, matematik ve istatistikten de yararlanarak karar alma ve öngörüye katkıda bulunacak problemlerin çözümü için birçok alanda kullanılmaktadır. Bunlar arasında sağlık alanı, başarılı sonuçlar elde edildiğinde hem doktorlara hem de hastalara fayda sağlayacağı düşünülen önemli bir sektördür. Yapılan tez çalışmasında, akut apandisit teşhisinde hekime yardımcı olabilecek bir karar destek sisteminin geliştirilmesi amaçlanmıştır. Sistemin geliştirilmesinde istatistiksel yöntemlerinden, lojistik regresyon analizi ve makine öğrenmesi yöntemlerinden destek vektör makinesi (DVM) yöntemi birlikte kullanılmıştır.

Çalışma kapsamında KTÜ Tıp Fakültesi Farabi Hastanesi Acil Tıp Servisine 2010-2016 yılları arasında karın ağrısı şikayeti ile başvuran ve akut apandisit tanısı alan ve akut apandisit tanısı almayan 220 hasta verisi kullanılmıştır. Bu hasta verileri uzman hekim danışmanlığında biyokimya laboratuvar test sonuçları ve epikriz raporları incelenerek elde edilmiştir. Cinsiyet, yaş, lökosit, trombosit, nötrofil, lenfosit, PDW (Trombosit dağılım genişliği), MPV (Ortalama trombosit hacmi), CRP (C-reaktif protein), glukoz, BUN (Kan üre azotu), kreatinin, total protein, albumin, total bilirubin, direkt bilirubin, AST (Aspartat aminotransferaz), ALT (Alanin aminotransferaz), amilaz parametrelerine ait veriler, lojistik regresyon analizine tabi tutularak aralarından nitelikli olanlar seçilmiştir. Sonrasında bu nitelikli parametrelere ait veriler rastgele olarak, eğitim ve test seti olmak üzere iki gruba ayrılmıştır. Eğitim setindeki 132 hasta verisi

kullanılarak DVM yöntemi yardımıyla hibrit bir karar destek sistemi geliştirilmiştir. 88 test verisi üzerinde; DVM modeli için %87 duyarlılık, %79 özgüllük ve %82 doğruluk değerleri elde edilmiştir.

Anahtar Kelimeler: Abdominal ağrı, akut apandisit, destek vektör makineleri, karar destek sistemi, klinik karar verme, lojistik regresyon analizi, makine öğrenmesi



2. SUMMARY

Acute Appendicitis Hybrid Decision Support System

Acute appendicitis is an inflammation that develops due to occlusion of appendix lumen. It is treated by surgical removal of the inflamed appendix. It can be difficult to diagnose appendicitis. Because its symptoms can also be seen in many other diseases. It is especially difficult to diagnose appendicitis since its location is variable. Unfortunately, some patients with acute appendicitis may be exposed to peritonitis or other complications during their diagnosis process. These patients have higher mortality rates than patients who are diagnosed timely. In this respect, early diagnosis of acute appendicitis is of great importance to the patient. There are various methods for the diagnosis of appendicitis. One such method is machine learning.

Machine learning is used in many areas for solving problems that contribute to decision making and prediction by taking advantage of machine learning algorithms, artificial intelligence, mathematics and statistics. Among them, healthcare field is an important sector where machine learning exercise is thought to be beneficial to both physicians and patients when successful results are obtained. In this thesis, it is aimed to develop a decision support system which can help the diagnosis of acute appendicitis. In the development of the system, statistical methods, logistic regression analysis and one of machine learning method, support vector machine (SVM) are used together.

The data used in the study includes 220 patients who were admitted to the Emergency Medical Service of KTU Medical Faculty Farabi Hospital with abdominal pain complaint between 2010 and 2016 years and who were or were not diagnosed with appendicitis. This patient data was obtained by examining biochemical laboratory test results and epicrisis reports in a specialist physician consultancy. Logistic regression analysis is used to select qualified data on the parameters of Gender, Age, Leukocyte, thrombocyte, neutrophil, lymphocyte, PDW (Platelet Dispersion Width), MPV (Mean Thrombocyte Volume), CRP (C-reactive protein), glucose, BUN (Blood Urea Nitrogen), creatinine, total protein, albumin, total bilirubin, direct bilirubin, AST (Aspartate aminotransferase), ALT (Alanine aminotransferase), and amylase. Subsequently, data on the qualified parameters were randomly divided into two groups, the train and the test

sets. A hybrid decision support system was developed through SVM method, using 132 patient data from the train set. On the 88 test data, 87% sensitivity, 79% specificity and 82% accuracy values were obtained for the SVM model.

Key Words: Abdominal pain, acute appendicitis, decision support model, clinical decision making, logistic regression analysis, machine learning, support vector machines



3. GİRİŞ ve AMAÇ

Günümüzde makineler, insanlığın işgücüne sağladıkları yararı, makine öğrenmesi yöntemleri ile birleştirdiklerinde beyin gücünü de sağlamayı başarmışlardır. Uygulama alanı ne olursa olsun, çok miktardaki verinin analiz edilerek gelecek ile ilgili tahminlerde bulunması ve bizim karar vermemize yardımcı olması ile makine öğrenmesi yöntemlerinin her geçen gün önemi artmaktadır. Bu gelişme diğer alanlarda olduğu gibi tıp alanında da ilgi odağı haline gelmiştir. Özellikle tıp alanındaki verinin büyüklüğü ve hayati önem taşıması bu alandaki uygulamaları daha da önemli kılmaktadır. Makine öğrenmesi ve veri madenciliği yöntemleri ile sağlık alanında hekimlere yardımcı olmak amacıyla birçok hastalığın sınıflandırılması, tahminlenmesi, risk hesaplanması gibi önemli çalışmalar yapılmaktadır. Akut apandisit de bunlardan biridir.

Akut apandisit tanısının ve ayırıcı tanısının iyi yapılması için mevcut olan testlerden hiçbirinin %100 duyarlılığı ve özgüllüğü yoktur. Çocuklarda, yaşlılarda ve premenapozal kadınlarda ilerleyen tekniklere rağmen negatif apendektomiler %25-30 gibi yüksek bir değerdedir (1). Negatif apendektomi oranları %10 ile %30 arasında değişen oranlarda bildirilmekte halen ciddi bir problem olarak karşımızdadır. Perfore apandisit oranları- nın %3-30 arasında değişmesi negatif apendektomileri kabul edilebilir kılabilmektedir (2). Bu oranların yüksek oluşunun nedenlerinin başında cerrahi kararının geç alınması sayılabilir. Negatif laparotomi nedenlerinin başında ise tanıda gecikmeye bağlı perforasyon oluşumundan korkulması gelmektedir.

Chung-Ho Hsieh ve arkadaşları tarafından 2010 yılında yayınlanan bir çalışmada 180 veri üzerinde % 94 duyarlı bir random forest algoritması geliştirilmiştir. Bu sayede akut apandisit olma olasılığını %94 oranında doğru tahmin edebilen akıllı bir yardımcı sistem elde edilmiştir (3).

Hsien-Wei Ting ve arkadaşları tarafından 2010 yılında yapılan bir çalışmada veri madenciliği ve karar ağacı yöntemleri kullanılarak akut apandisit olma riskini tahmin eden bir model geliştirilmiştir. 532 veri üzerinde %94 duyarlılıkta başarılı bir sistem elde edilmiştir (4).

S.G. Prabhudesai ve arkadaşları tarafından 2007 yılında yayınlanan bir çalışmada prospektif bir çalışma ile toplanan 60 veri üzerinden klinisyen, Alvarado skoru ve yapay

sinir ağırları yöntemlerinin apandisit tanısı üzerindeki doğruluğu karşılaştırılmış ve %97 oranında başarılı bulunan yapay sinir ağı yönteminin etkili ve doğru bir araç olabileceği görülmüştür (5).

Akut apandisit tanısı öykü, fizik muayene, laboratuvar ve görüntüleme yöntemlerinin birlikte değerlendirilmesi ile konulur. Tek başına tanı koydurabilecek bir yöntem yoktur. Ultrasonografi, tomografi ve laparoskopinin kullanımının yaygınlaşmasına rağmen tanıda beklenen doğruluk oranları istenilen seviyelere ulaşmamıştır. Özellikle kadınlarda negatif apendektomi oranlarının, çocuk ve yaşlılarda komplikasyonların yüksek oluşu düşündürücüdür. Bu nedenle tanıda kullanılabilecek yeni yöntemler araştırılmaktadır. Konuyla ilgili tek başına tanı koydurabilecek testleri araştıran pek çok makale yayınlanmıştır. Ancak bunların hiçbirisi kesin tanı koydurabilen yöntem olamamıştır. Bunun sonucunda mevcut tanı yöntemlerinin birlikte kullanılmasıyla elde edilen skorlama sistemlerinin kullanımı gündeme gelmiştir. 80'li yıllardan başlayarak bu tarz skorlama sistemlerinin kullanımı önerilmektedir. (6)

Bu tez çalışmasında lojistik regresyon ve makine öğrenmesi yöntemlerinden DVM birlikte kullanılarak, akut apandisit hibrit karar destek sistemi geliştirilmiştir. Bu sistem sayesinde standart uygulamalara alternatif olarak, kısa sürede akut apandisit tanısı koymada ve uygun tedaviye hızlıca başlamada hekimlere yardımcı olunabilir. Çalışmanın neticesinde, yaş, cinsiyet, lökosit, lenfosit, total protein, CRP ve AST değişkenleri, giriş verisi olarak kullanılmış ve akıllı bir akut apandisit karar destek sistemi geliştirilmiştir.

4. GENEL BİLGİLER


Apandis ilk olarak embriyolojik gelişimin 6-8. haftasında çekumun (İnce barsağın sonlanıp kalın barsağın başladığı yer olan barsak bölümü) terminal bölümünde bir kabartı şeklinde görünür hale gelir. Apandisin uzunluğu 1 cm'den kısa ya da 30 cm'den uzun olabilir; ancak büyük çoğunluğu 6-9 cm uzunluğundadır. Apandisin histolojik yapısı kolonun yapısına benzer görünümündedir. Mukoza, submukoza, muskularis propria ve seroza olmak üzere dört tabakadan oluşur (7).

Acil servislere başvuruların %10'u karın ağrısı nedeniyledir (8). Karın ağrısı ile başvuranlarda saptanan en sık cerrahi neden ise akut apandisitir (9, 10). Günümüzde tüm dünyada yapılan en sık acil ameliyat apendektomidir. Uzun yıllar yanlış bir inanışla apandis hiçbir fonksiyonu bulunmayan bir organ olarak görülmüştür. Günümüzde ise, başta sekretuvar IgA olmak üzere immünglobulin salgılanmasında aktif rol alan immünolojik bir organ olarak tanımlanmaktadır (11).

4.1. Akut Karın Ağrısı

"Akut karın tablosu" acil cerrahi ünitelerinde sık karşılaşılan bir durum olup, tanı ve tedavi yöntemlerinin gelişmesine rağmen halen ciddi bir sorun olarak karşımıza çıkmaktadır. Bir cerrah için akut karında, doğru tanı ve tedavi her zaman için mümkün olmayabilir. Akut karın terimi sıklıkla acil cerrahi müdahaleyi gerektiren bir durumu ifade etse de acil operasyon bu hastaların hepsinde uygulanmamaktadır. Akut karında barsak obstrüksiyonu, perforasyon ve yaygın peritonitten abdominal aort anevrizması rüptürü, narkotik ilaç eksikliği ve ailevi akdeniz ateşi'ne varan bir hastalık yelpazesi mevcuttur.

Akut karın tablosunda, akut karının sebepleri göz önüne alınarak gerekli incelemeler yapılmalı, tanı konulduktan sonra spesifik sebeplere yönelik tedaviler yapılmalıdır. Akut karın tablosunun değerlendirilmesinde anamnez ve fizik muayene en önemli bölümü oluşturur. Bunun yanı sıra hastanın yaşı, ağrının özellikleri, bulantı ve kusma olması, barsak alışkanlıklarındaki değişiklikler (diyare, konstipasyon) de tanıda önemlidir (12).




Şekil 1. Karın ağrısı sınıflandırması (12)

* (12)'den uyarlanmıştır.

Akut karın ağrısı Şekil 1'deki gibi sınıflandırılarak, apandisit tanısında düşünülmesi gereken hastalıklar gösterilmiştir.

4.2. Akut Apendisit

Akut apandisit, en iç tabakadan yani mukozadan başlar ve apandis duvarı boyunca yayılır. En sık fekalit ya da apendikolit denen sertleşmiş-taşlaşmış gaita ile olur. İkinci sık neden ise bakteriyel ve viral infeksiyonlara bağlı lenfoid hiperplazinin basıdır. Tıkanmanın ardından içeride mukus birikir, basınç artar, bakteri proliferasyonu olur. Basınç artışı serozanın gerilmesine ve önce lenfatik akımın bozulmasına, bu da ödeme neden olur, apandis çapı artar. Buraya kadar hastaların yarısında göbek çevresinde künt bir ağrı olur (visseral ağrı dönemi). Basınç daha da artınca venöz iskemi gelişir. Lümendeki mukus pü haline dönüşmüştür (süpüratif apandisit). En son aşamalar venöz ve arteriyel tromboz, gangren ve perforasyondur. Bu dönemlerde sağ alt kadranda ağrısı vardır (parietal ağrı). (13).



4.2.1. İnsidans (Sıklık)

Yaşam süreci boyunca apandisit gelişme riskinin %6-20 arasında olduğu bilinmektedir. Bebeklikte apandis tabanının geniş olmasına bağlı olarak bu risk düşük iken, 15 yaşın altında bu risk %1'e çıkmakta ve 10-12 yaş civarında en yüksek düzeyde izlenmektedir. Blair ve arkadaşlarının, 2,216 apandisit piyesini inceledikleri bir çalışmalarında 1.3:1 oranında erkeklerde daha sık olduğu belirlenmiştir. Halen apendektomi girişimlerinin %84'ü akut patolojiler nedeniyle gerçekleştirilmekte ve olguların ortalama %16'sında normal apandis bulunmaktadır. Normal apandis belirlenen olguların da %68'ini kadın hastalıkları oluşturmaktadır (14). Akut apandisitte morbidite oranı %15-20 arasındadır (15).

4.2.2. Akut Apandisit Tanısı

Akut apandisitte tanı, hikâye ve klinik bulgularla konur. Laboratuvar ve görüntüleme tetkikleri tanıyı destekler ama asla ekarte etmez. Akut apandisit tanısı koymanın olmazsa olmazı, hastanın hikâyesi ve fizik muayenesidir. Laboratuvar ve

görüntüleme tanıda sadece yardımcıdır. Tetkik sonuçlarına göre akut apandisit tanısı ekarte edilemez.

Akut apandisitte genelde semptomlar belirli bir sırayı takip eder:

1. Periumblikal ağrı (visseral, lokalize edilemeyen)
2. İştahsızlık, bulantı ve/veya kusma
3. Sağ alt kadranda ağrısı ve hassasiyet
4. Ateş
5. Lökositoz

Bu semptom ve bulguların hepsi de aynı zamanda birlikte bulunmayabilir (16).

4.2.2.1. Apandisitte Karın Ağrısı

Apandisit belirtileri arasında en bilineni karın bölgesinde yaşanan ağrılardır. Karın bölgesine yayılan ağrılar donuk ve sürekli. Ancak karının sağ alt kısmını doğru ilerledikçe ağrı şiddetlenir ve “bıçak gibi” olarak tabir edilen ağrılar yaşanabilir. Mekanik uyarım ya da hareketle artan ağrı vardır. Karın bölgesinin genelinde “donuk” bir ağrı, karının sağ alt kısmında ise keskin ve şiddetli ağrılar oluşabilir. Sağ bölgedeki ağrı genellikle kalça kemiğinin hemen üst kısmına denk gelmektedir. Ağrıya kusma, mide bulantısı, ateş, kabızlık ya da ishal, gaz sorunu ve sırt ağrısı gibi diğer belirtilerde eşlik edebilir ancak, ağrı dışında görülen bu belirtiler her kişide ortaya çıkmayabilir. Visseral fazda ağrı künttür ve göbek deliği etrafındadır. Fakat ortalama 4-6 saat sonra ağrı lokalize olur ve şiddetlenir. Bu, somatik faz başlangıcını gösterir. Ağrı sağ alt kadrana lokalize olur (17).

4.2.2.2. Fizik Muayene

Sağ alt kadranda hassasiyeti %96 olguda görülmektedir ancak bu nonspesifik bir bulgudur. En spesifik muayene bulgusu ise sağ alt kadranda rebound hassasiyeti, perküsyon hassasiyeti, rijidite (istemsiz karın kaslarının kasılı olması) ve defanstır (istemli veya istemsiz olarak karın kaslarının kasılması). Tanımlanan diğer muayene bulgularının klinik önemi pek yoktur. Öksürük ile ağrının artması Dunphy işareti olarak adlandırılmıştır. Rektal muayenenin tanı koymada her olguda yararı kesin olmamakla

birlikte yapılmaması tüm akut karın düşünülen olgularda olduğu gibi önemli bir eksiklik ve hatadır (18).

4.2.2.3. Laboratuvar bulguları-testleri

Tam Kan Sayımı

Tam kan sayımı ucuz ve geniş kabul gören bir tetkiktir. Çalışmalar göstermiştir ki apandisiti olan erişkinlerin %80-85'inde lökosit sayısı 10.000'nin üzerindedir. Hastaların %78-95'inde nötrofil oranı %75'in üzerindedir. Apandisit olgularının ancak %4'ünde negatif sonuç (10.000'in altında lökosit sayısı) vermektedir. Sağ alt kadranda ağrısının diğer nedenlere bağlı olduğu hastalarda da lökosit sayımı %70 oranında 10.000'in üzerine çıkmaktadır. Bu da lökosit sayımının prediktif değerini düşürmektedir (18).

Biyokimyasal Araştırmalar

Akut apandisitte tanıya götürecek spesifik bir biyokimyasal test mevcut değildir. Ancak bazı testler tanıyı desteklemek amacı ile kullanılabilir (18).

➤ Prokalsitonin (PCT)

Mevcut inflamatuvar cevap indikatörlerinden farklı yeni bir diagnostik parametre prokalsitonindir (PCT) (19).

➤ C-Reaktif Protein (CRP)

Bakteriyel enfeksiyona normal reaksiyon olarak karaciğerde yapılır. Sağlıklı kişilerde serumdaki konsantrasyonu çok düşüktür, yok gibidir. Bakteriyel enfeksiyondan sonra 8 saat içinde giderek yükselir. Prospektif randomize çalışmalar, 24 saatten uzun süren semptomları olan hastaların CRP'si normal ise %100 yakın apandisit tanısından uzaklaşabileceğini göstermiştir (18, 20).

4.2.2.4. Radyolojik Çalışmalar

Direkt Karın Grafisi

Diğer akut karın bulgularında olduğu gibi akut apandisitte de yararı çok azdır. Bu nedenle kullanılmasının maliyet ekleyeceği ve bu nedenle çok gerekli olmadığını savunan yayınlar da vardır (14).

Ultrasonografi

Ultrasonografinin avantajları arasında; noninvaziv olma, kısa sürede uygulanabilirlik, radyasyona maruz kalamama, karın ağrısının diğer etyolojilerini belirleme sayılabilir. En önemli devavantajı ise yapan kişiye bağımlı olmasıdır. Yine de özellikle üreme çağındaki kadınlarda pelvik patolojilerini ekarte etmek üzere tomografiden önce yapılması yararlı olabilir (18).

Diğer Radyolojik Tetkikler

Bilgisayarlı Tomografi (BT), radyoizotop işaretli lökosit sintigrafisi, baryumlu grafi ve MR nadir olarak kullanılan diğer radyolojik tetkiklerdir. Birçok çalışmada BT'nin apandiks apsesi durumunda perkütan drenaj planlandığında tercih edilmesinin avantajlı olduğunu vurgulamaktadır (16). BT apandisit tanısında altın standart olmasına rağmen her hastaya uygulanması hem hasta sağlığı (radyasyon riski) hem de maliyet yönünden zordur (21).

Klinik Tanısal Skorlamalar

1983 yılında Teicher ve ark. tarafından önerilen 8 parametrelilik skorlama sisteminin ardından 1986 yılında Alvarado tarafından bugün en çok kabul gören MANTRELS skorlaması yayınlanmıştır (22, 23). Sonrasında ise Ohmann, Tzanakis, Andersson skorlama sistemleri ile ilgili çalışmalar yayınlanmıştır. Özellikle görüntüleme yöntemi kullanılmayan merkezlerde skorlama sistemlerinin negatif apendektomi oranlarını azalttığı ve komplikasyon gelişmeden operasyon kararı alınmasına yardımcı olduğu gösterilmiştir. Mevcut skorlama sistemlerinin tanı değerlerinin yüksek olduğu belirtilmektedir (24). Ancak çoğu karmaşık hesaplamalar gerektirmekte ve hatırd tutulması zor çok sayıda parametre içermektedir.

4.2.3. Tedavi

Apandisit tedavisi inflamasyonun cerrahi olarak çıkarılmasıdır. Apendektomi açık olarak veya laparoskopik girişimle yapılabilir. Klasik tedavi açık apendektomidir (25).

4.3. Lojistik Regresyon Analizi

Gözlemleri verilerin yapısında bulunan olası gruplara atamak için kullanılan yöntemlerden üç tanesi, kümeleme (clustering), diskriminant (discriminant) ve lojistik regresyon (logistic regression) analizidir.

Kümeleme analizinde verilerin yapısındaki grup (küme) sayısı bilinmemekte, gözlemler uzaklık ya da benzerlik ölçütlerine göre kümelenmektedir (26). Veriler veya uzaklık değerleri normal dağılımlı olmalıdır (27).

Ayırma (Discriminant) analizi, verilerin sınıflandırılması ve belirli olasılıklara göre belirli sınıflara atanmasını sağlayan bir yöntemdir. Fakat ayırma analizi çok değişkenli normal varsayımını ön koşul kabul etmektedir. Lojistik regresyon ise herhangi bir varsayım ileri sürmeksizin birimlerin sınıflama işlemlerini yerine getiren ve ayırma analizine alternatif bir yöntemdir.

Basit ve çoklu regresyon analizi uygulanabilmesi için değişkenlerin bazı varsayımları yerine getirmesi gerekir. Bu koşulların sağlanamadığı veri setlerine basit ya da çoklu regresyon analizleri uygulanamaz. Lojistik regresyon analizi, normal dağılım varsayımı ve süreklilik varsayımı ön koşulu gerektirmeyen bir yöntemdir (28).

Lojistik regresyon analizinin kullanım amacı, istatistikte kullanılan diğer model yapılandırma teknikleri ile aynıdır. En az değişkeni kullanarak en iyi uyuma sahip olacak şekilde bağımlı ile bağımsız değişkenler arasındaki ilişkiyi tanımlayabilen ve biyolojik olarak kabul edilebilir bir model kurmaktır. Lojistik regresyon modelleri, son yıllarda biyoloji, tıp, ekonomi, tarım ve veterinerlik ve taşıma sahalarında yaygın olarak kullanılmaktadır (29).

Lojistik regresyon analizinde bağımlı değişkenin yapısına bağlı olarak üç temel yöntem vardır:

1. İkili Lojistik Regresyon (BLOGREG, Binary Logistic Regression)
2. Sıralı Lojistik Regresyon (OLOGREG, Ordinal Logistic Regression)
3. İsimsel Lojistik Regresyon (NLOGREG, Nominal Logistic Regression, Multinomial Logistic Regression) (30).

4.3.1. Lojistik Regresyon Analizinde Değişken Seçimi

Lojistik regresyon analizi; sürekli, kesikli, ikili yada bunların herhangi bir karışımı olan veri setlerinden kategorik bir sonucu tahmin etmeye olanak sağlar. Lojistik regresyon modelinde;

- a) Sadece kategorik bağımsız değişken/değişkenler,
- b) Sadece sürekli bağımsız değişken/değişkenler,
- c) Hem kategorik hem de sürekli bağımsız değişkenler yer alabilir.

Bağımlı değişkendeki varyasyonu açıklamak için kurulan bir regresyon eşitliğine girecek değişken sayısı ne kadar çok olursa, eşitlik o kadar küçük hata taşımaktadır. Lojistik regresyon denklemlerinde bulunan bağımsız değişkenlerin tümünün bağımlı değişkeni açıklamak için etkili olması her zaman mümkün olmamaktadır. Hatayı açıklayamayan değişkenlerin denklemde tutulması lojistik regresyon denkleminin etkinliğini ve tahmin gücünü düşürmektedir. Ölçülecek olan bağımsız değişkenlerden de bazılarının denklemde önemli bir etkide bulunmamaları durumunda, bu değişkenlerin ölçümleri ile yapılacak olan gereksiz harcamaları ortadan kaldırmak amacıyla değişken eleme yöntemleri olarak bilinen istatistik yöntemler kullanılmaktadır. Değişken seçimi yöntemlerinden yaygın olarak bilinenleri; “ileri doğru seçim” (forward selection), “geriye doğru eleme” (backward elimination) ve “tüm olası regresyon yaklaşımı” (all possible regression) gibi değişik yaklaşımları mevcut olan adımsal regresyon (stepwise), ve en iyi regresyon modeli bulma (best regression) yöntemleridir (30).

4.3.2. Lojistik Regresyon Modelinin Kurulması ve Parametre Tahmin Yöntemleri

Lojistik regresyon fonksiyonu,

$$\pi(x) = \frac{\exp(\beta_0 + \beta_1 X)}{1 + \exp(\beta_0 + \beta_1 X)} \quad (4.1)$$

şeklindedir. Bu ifadenin bir diğer şekli ise,

$$\pi(x) = [1 + \exp(-\beta_0 - \beta_1 X)]^{-1} \quad (4.2)$$

olarak yazılabilir. $\pi(x) = E(Y/x)$ değeri şartlı ortalama olarak bilinir. Şartlı ortalamanın, modelde yer alan parametrelerle $(\beta_0 + \beta_1)$ doğrusal hale dönüştürülmesi için,

transformasyona tabi tutulması gerekir. Bu transformasyona Logit transformasyon adı verilir ve aşağıdaki şekilde gösterilir:

$$g(x) = \ln \left[\frac{\pi(x)}{1 - \pi(x)} \right] = \beta_0 + \beta_1 x \quad (4.3)$$

Transformasyon değişkeni $g(x)$, modeldeki parametrelerle doğrusaldır, sürekli ve $-\infty, +\infty$ aralığında değişen değerler alır. $\pi(x)$ arttıkça $g(x)$ 'te artar ve eğer $\pi(x) < 0.5$ ise $g(x)$ negatif, $\pi(x) > 0.5$ ise $g(x)$ pozitif değerler alır. Modelin sonuç değişkeninin sınırlarını genişletmek için uygulanan Logit transformasyonunun bazı özellikleri şöyle sıralanabilir:

1. p arttıkça $\text{lojit}(p)$ de artar.
2. p , 0 ile 1 arasında iken $\text{lojit}(p)$ reel sayılar doğrusu üzerinde değerler alabilir.
3. $p < 0.5$ olduğunda $\text{lojit}(p) < 0$ ve $p > 0.5$ olduğunda $\text{lojit}(p) > 0$ olur.

Doğrusal regresyon modelinde bağımlı değişkene ait bir gözlem $y = E(Y/x) + \varepsilon$ şeklinde gösterilebilir. ε hata terimi olarak isimlendirilir ve gözlemin koşullu olasılıktan ne kadar saptığını gösterir. ε 'nin ortalamasının sıfır ve varyansının ise bağımsız değişkenin her düzeyinde sabit olacak şekilde normal dağılım göstereceği genel bir varsayımdır. Bu varsayım bağımlı değişken iki düzey içerdiği zaman geçerli değildir. Bu tür durumlarda x verildiğinde sonuç değişkeninin değeri $y = \pi(x) + \varepsilon$ ile gösterilir. Ve ε 'nin mümkün olan iki değerden başka değer alamayacağı varsayılır. Eğer $y = 1$ ise, $\pi(x)$ olasılıkla $\varepsilon = 1 - \pi(x)$ değerini alır ve eğer $y = 0$ ise, $1 - \pi(x)$ olasılıkla $\varepsilon = -\pi(x)$ değerini alır. Böylece ε , sıfır ortalamalı ve $\pi(x)[1 - \pi(x)]$ 'a eşit varyanslı binomiyal bir dağılım gösterir (29).

Lojistik regresyon analizinde katsayıların tahmin edilmesinin ardından, uygun bulunan modelin içerdiği değişkenlerin anlamlılığı değerlendirilmektedir. Modelin uygun olup olmadığı “model ki-kare” testi ile, her bir bağımsız değişkenin modelde varlığının anlamlı olup olmadığı ise Wald istatistiği ile test edilir.

Parametre tahmini için “En çok olabilirlik yöntemi” hariçinde "Yeniden ağırlıklandırılmış iteratif en küçük kareler yöntemi", "Minimum logit ki-kare yöntemi"

ve bunların hariçinde çok özel durumlarda kullanılan kestirim yöntemleri de bulunmaktadır.

Lojistik regresyon analizi uygulanırken izlenecek işlem sırası aşağıdaki gibidir:

- Katsayıların en çok olabilirlik tahmin edicisi (Maximum likelihood) yardımıyla tahmin edilmesi,
- Katsayıların yorumlanması,
- Katsayılara ait hipotez kontrollerinin yapılması,
- Modelin başarısının değerlendirilmesi (31).

4.3.4. Uyum İyiliği İstatistikleri

Literatürde lojistik regresyon modelinin uyum iyiliğini belirlemek için geliştirilmiş çeşitli yöntemler mevcuttur. Bunlardan biri de Hosmer-Lemeshow testidir. Teste ait H_0 hipotezi “yapılan tahminler, gözlenen değerlere çok iyi uymaktadır” demektedir. Bu nedenle, test sonucunun istatistiksel olarak anlamlı çıkmaması ($p > 0.05$), modelin iyi uyumlu bir model olduğunu göstermektedir. Literatürde, Hosmer-Lemeshow testi’nin veri setinin büyüklüğünden etkilendiği, veri seti büyüdükçe gözlemlenen ve tahmin edilen değerler arasında anlamlı daha da küçük farklılıklar bulunduğu tespit edilmiştir. Lojistik regresyon modelinde tahmin edici nitelikler ile tahmin arasındaki ilişkinin ortaya konabilmesi için kullanılan yöntemlerden biri Nagelkerke R^2 değeridir. Nagelkerke R^2 , logistik regresyon modelindeki açıklanan varyans miktarını belirtir ve 1 mükemmel model uyumunu göstermektedir (32).

4.4. Makine Öğrenmesi Yaklaşımı


Makine öğrenmesi, performans optimizasyonu için örnek veri ya da geçmiş deneyimleri kullanarak bilgisayar programlamaktır (33).

Bugün makine öğrenmesi çalışmaları, yapay zekâ, matematik ve istatistikten de yararlanarak karar alma ve öngörüye katkıda bulunacak problemlerin çözümü için kullanılmaktadır. En yalın hali ile makine öğrenmesi, bir makinenin (genellikle bir bilgisayarın) bir işi yapmayı öğrenmesini hedeflemektedir. Simon (1984) öğrenmeyi, bir sistemin aynı görevi ikinci defa gerçekleştirmesinde ya da aynı popülasyonla oluşturulan yeni bir görevde daha iyi performans sergilemesini sağlayacak her türlü

değişiklik olarak ifade etmiştir. Makine öğrenmesinde öğrenme işi, kullanılan veri setleri ve algoritmalar ile sağlanmaktadır. Sınıflandırma, makine öğrenmesinin popüler ve temel uygulama alanlarından biri olup, bilinmeyen bir veri parçasını bilinen bir gruba yerleştirmekte kullanılmaktadır (34).

İnsan beyninin doğuştan öğrenebilme yeteneği vardır. Fakat makineler için aynı durum söz konusu değildir. Bir makinenin öğrenebilmesi için gerekli şartların açıkça belli olması gereklidir. Öğrenen varlığın makine ya da insan olmasına bakılmaksızın, ana öğrenme süreci ikisinde de benzerlik göstermektedir. Bu öğrenme süreci birbiriyle ilişkili dört ögeden meydana gelir:

- **Depolama:** Gözlemlerden, hafızadan ve çağrışımlardan faydalanır.
- **Soyutlama:** Depolanmış veriyi daha kapsamlı simgelere ve kavramlara dönüştürür.
- **Genelleştirme:** Bilgi ve çıkarımları oluşturmak için soyutlanmış veriyi kullanır.
- **Değerlendirme:** Öğrenilen bilginin kullanılabilirliğini ölçmek ve olası gelişmeleri haber vermek için bir geribildirim mekanizması kullanır (35).



Şekil 3. Makine öğrenmesinin aşamaları (36)

Makine öğrenmesi en yalın hali ile geçmiş deneyimlerden geleceği tahmin etmektir (37). Makine öğrenmesi, veriden öğrenmeye dayalı bir yöntem olup, çıktıların sınıflanması veya kümelenmesini sağlayabilecek algoritmaları meydana getiren bir tekniktir. Kullanılan algoritmalar sayesinde makine öğrenmesi gerçekleşir. Bu öğrenme yöntemi uygulamasında, veri setinde çıktı değerleri biliniyorsa danışmanlı/egitmenli öğrenme (Supervised learning), bilinmiyorsa danışmansız/egitmensiz öğrenme (Unsupervised learning) algoritmaları kullanılmaktadır (38).

4.5.1. Danışmanlı Öğrenme

Danışmanlı öğrenme yönteminde, amaç sınıflandırmayı sağlayabilecek bir model oluşturmaktır. Bu öğrenme yönteminde elde edilecek sonuç, tahmini istenen çıktı değerini ya da etiketlenmiş değer in önceden bilinmesi durumudur. Diğer bir deyişle girdi değerleri bir danışman (veya eğitmen) tarafından çıktı değerlerine etiketlenir. Böylece, danışman desteğinde eğitilen veri seti çıktı değerlerinin tahmin edildiği bir model oluşturulur. Bu model, tahmin edilen çıktı değerleri ile bilinen çıktı değerleri arasındaki farkın en aza indirildiği bir model şeklidir (38).

4.5.2. Danışmansız Öğrenme

Danışmansız öğrenme yönteminde, birbirine yakın örnekler benzerliklerine göre kümelenmekte veya ilişkileri dikkate alınarak birliktelik analizleri ile model oluşturmaya gerek kalmadan çözümler üretilmektedir. Çıktı değerinin olmadığı veya bilinmediği durumlarda sadece girdi değerlerinden hareket edilerek girdilerin gruplanması, diğer bir deyişle kümelenmesi (clustering) sağlanmaktadır (38).

Yapılan bu tez çalışmasında, akut apandisit tanı sisteminin geliştirilmesi için danışmanlı öğrenme yaklaşımlarından biri olan DVM (Destek Vektör Makineleri) yöntemi kullanılmıştır.

5. GEREÇ ve YÖNTEMLER

5.1. Çalışmada Kullanılan Yöntemlerin Detayları

Bu tez çalışması kapsamında gerçekleştirilen çalışmada lojistik regresyon analizinde geriye doğru adımsal eleme yöntemi kullanılarak önemli parametreler seçilmiş ve sonrasında makine öğrenmesi yöntemlerinden destek vektör makineleri tekniği yardımıyla hibrit bir karar destek modeli geliştirilmiştir. Bu teknikler sırasıyla incelenecektir.

5.2. İleriye Doğru Seçim Testiyle Geriye Dönük Eleme (Backward Stepwise)

Lojistik regresyon modelinde değişken seçimi için çok farklı yöntemler mevcuttur. Bunlar tek değişkenli ve çok değişkenli analiz olmak üzere iki temel ayrıma göre yapılır. Çok değişkenli analiz iki yöntemi içermektedir. Bunlar adımsal (stepwise) yöntem ve en iyi alt setler yöntemidir. En iyi alt setler yöntemi lojistik regresyon analizinde pek kullanılmamaktadır. Adımsal yöntem ise ileri yönlü seçim (forward selection) ve geriye doğru eleme (backward elimination) olmak üzere ikiye ayrılmaktadır. Hata teriminin normal dağılım göstermesinden dolayı yeni değişkenin modele katkısının önemi için doğrusal regresyon analizinde F testinden yararlanılmasına karşın, lojistik regresyon modelinde hata terimleri binom dağılımı göstereceğinden buna G istatistiği ile karar verilir.

İleri yönlü seçim tekniğinde, değişkenler modele, yeni bir değişken uyumu arttırmayınca ya da eklenirler. Her bir adımda, uyumu en fazla arttıracak değişken seçilir. Geriye doğru eleme tekniğinde ise süreç en karmaşık tüm değişkenlerin modelde yer almasıyla başlar ve değişkenler ardıl olarak modelden çıkarılır. Her adımda, modele etkisi en az olan değişken modelden dışlanarak en uygun model bulunmaya çalışılır.

Olabilirlik oran testi, modelde yer alan bağımsız değişkenler için p katsayılarının tümünün anlamlılığının test edilmesinde de kullanılabilir. Modelin anlamlı olup olmadığının belirlenmesinde, değişken(ler)siz modelin log-olabilirliği değişken(ler) ile modelin log-olabilirliği ile kıyaslanmalıdır. Bu durum için G istatistiği aşağıdaki biçimde hesaplanır:

$$G = -2 \ln [\text{değişken(ler)siz olabilirlik} / \text{değişken(ler)li olabilirlik}] \quad (5.1)$$

Bu istatistik, lineer regresyonda kullanılan F testindeki pay kısmı ile aynı rolü üstlenir.

Modelin anlamlılığının kontrol edilmesinde hipotez takımları aşağıdaki gibidir:

$$H_0: \beta_1 = \beta_2 = \dots = \beta_p = 0$$

H_1 : En az biri 0'dan farklı

G istatistiği ($\gamma_2 - \gamma_1$) serbestlik dereceli ki-kare dağılımı göstermektedir. Serbestlik derecesi hesaplanırken kullanılacak γ_2 değeri tam modeldeki değişken sayısına 1 eklenerek ve γ_1 değeri ise düşürülmüş modeldeki değişken sayısına 1 eklenerek bulunacaktır. Eğer yukarıda verilen sıfır hipotezi red edilirse modelin anlamlı olduğu, eğer sıfır hipotezi kabul edilir ise, düşürülmüş modelin ancak tam model kadar iyi olabileceği sonucuna varılır (39). Bu da etkisiz bir varsayım olur.

Eğer adımsal bir method kullanılacaksa “geriye doğru eleme” (backward elimination), “ileri doğru seçim” (forward selection)’e tercih edilebilir. Çünkü ileriye doğru seçimin baskılayıcı etkisinden dolayı Tip II hata’nın oluşma olasılığı daha yüksektir (40).


5.3. Destek Vektör Makineleri (DVM)

Veri madenciliğinin görevlerinden biri olan sınıflandırma probleminin çözümü için geliştirilmiş önemli makine öğrenimi algoritmalarından biri destek vektör makineleri’dir. Literatürde destek vektör makineleri’nin diğer birçok tekniğe göre daha başarılı sonuçlar verdiği kanıtlanmıştır (41).

Son yıllarda, sınıflandırma problemlerinin çözümü için geliştirilmiş en başarılı makine öğrenimi algoritmalarından biri destek vektör makineleridir. Destek vektör makineleri, birçok sınıflandırma probleminin çözümünde başarıyla uygulanmış ve genelleme performansı yüksek ve etkin makine öğrenimi algoritmalarından biri olarak literatürdeki yerini almıştır. Destek vektör makineleri’nin en önemli avantajı, sınıflandırma problemini kareli optimizasyon problemine dönüştürüp çözmesidir. Böylece problemin çözümüne ilişkin öğrenme aşamasında işlem sayısı azalmakta ve diğer teknik algoritmalarla göre daha hızlı çözüme ulaşılmaktadır (41).

DVM, görüntü ve metin sınıflandırma, nesne tanıma, el yazısı tanıma, ses tanıma ve yüz tanıma gibi çeşitli örüntü tanıma uygulamalarında sıkça kullanılmaktadır. DVM, aynı zamanda biyolojik uygulamalarda da yükselen bir başarı göstermektedir. Tıpta ise kanser morfolojisinde, tedavi başarısının ve ilgili genin belirlenmesinde, çeşitli hastalıkların teşhisinde kullanılmaktadır. DVM pratikte daha çok sınıflama amacıyla kullanılmaktadır ve sağlık alanı araştırmalarında bir tanı yöntemi olarak tercih edilebilir (42).

DVM'nin sahip olduğu matematiksel algoritmalar başlangıçta iki sınıflı doğrusal verilerin sınıflandırılması problemi için tasarlanmış, daha sonra çok sınıflı ve doğrusal olmayan verilerin sınıflandırılması için genelleştirilmiştir. DVM'nin çalışma prensibi iki sınıflı birbirinden ayırabilen en uygun karar fonksiyonun tahmin edilmesi, başka bir ifadeyle iki sınıflı birbirinden en uygun şekilde ayırabilen hiper-düzlemin tanımlanması esasına dayanmaktadır (43).




Şekil 4. Destek vektör makineleri çalışma prensibi (44)

DVM literatüründe tahmin edici veya bağımsız (predictor) değişkene doğal nitelik (attribute), optimum hiper düzlemi belirlemek için kullanılan dönüştürülmüş doğal niteliğe belirleyici nitelik (feature) ve bir deneği (gözlemi) tanımlayan belirleyici nitelik setine ise vektör denilmektedir. Doğrusal olarak ayrılabilen verileri, ait oldukları boyutta bir düzlem ile ayırabilmek mümkünken doğrusal olarak ayıramayan verilerin ait oldukları boyuttan daha yüksek boyutlu bir uzaya taşınarak burada bir hiper düzlem ile ayırmak mümkün olacaktır (42).

5.3.1. Doğrusal Ayrılabilen Veriler için DVM

Doğrusal olarak ayrılabilen sınıflama problemleri, DVM'nin temelini oluşturur ve tanımı çok daha gelişmiş sistemleri anlamak için önemlidir. Destek vektör makineleri ile sınıflandırmada genellikle $\{-1,+1\}$ şeklinde sınıf etiketleri ile gösterilen iki sınıfa ait örneklerin, eğitim verisi ile elde edilen bir karar fonksiyonu yardımıyla birbirinden ayrılması amaçlanır. İki sınıflı veriler doğrusaldır ve bu verileri birbirinden direkt olarak ayırabilen birçok hiperdüzlem (doğru) çizilebilmektedir. Ancak DVM'nin amacı, bilinmeyen veri seti ile karşılaştığında sınıflama hatasını en küçük yapacak hiperdüzlemi seçmektir. Bu hiperdüzlem, iki örnek grubuna eş uzaklıkta olacaktır. Bunun için maksimum marjınlı hiperdüzlem tekniği önerilmiştir (42, 43).




Şekil 5. Doğrusal olarak ayrılabilen iki sınıflı sınıflama problemi (42)

5.3.2. Doğrusal Ayrılamayan Veriler için DVM

Verilerin doğrusal olarak ayrılamadığı durumlar ile karşılaşıldığında DVM'ler, (mapping) yaparak verilerin boyutlu orijinal girdi uzayından daha yüksek boyuta sahip belirleyici nitelik (feature) uzayına taşır. Doğrusal olmayan DVM, verilerin taşındığı bu yeni boyutta doğrusal DVM gibi çalışarak verileri ayıracak optimum hiperdüzlemi arar.

Doğrusal olmayan DVM'ler $\Phi(x)$ haritalama fonksiyonu kullanırlar, bu fonksiyon hesaplanamaz. Çözümü karmaşık, zor hesaplamalar gerektirdiğinden bu sorunu önlemek amacıyla, matematiksel olarak $K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j)$ şeklinde ifade edilen bir kernel fonksiyonu yardımıyla doğrusal olmayan dönüşümler yapabilmekte ve bu şekilde verilerin yüksek boyutta doğrusal olarak ayırılmasına imkan sağlamaktadır (42).



Şekil 6. Doğrusal olarak ayrılamayan verilerin farklı boyutlardaki uzaylara aktarılması (42)

Literatürde DVM’de kullanılan birçok çekirdek fonksiyon bulunmaktadır. Ancak bu fonksiyonlardan doğrusal fonksiyon, polinomiyal fonksiyon, sigmoid fonksiyon ve Radyal Tabanlı Fonksiyon (RTF) en çok kullanılanlarıdır. Polinomiyal çekirdek fonksiyon, RTF’ye göre daha fazla parametre içerir. Bu yüzden, RTF’nin hesaplanması daha kolaydır. Ancak, düşük derecelerde polinomiyal çekirdek fonksiyon ile iyi sonuçlar alınabiliyorsa polinomiyal çekirdek, sınıflandırılabilen kısımlar oluyorsa RTF kullanılmalıdır. Doğrusal çekirdek fonksiyon ise, özellik sayısının çok fazla olduğu durumlarda daha iyi sonuçlar vermektedir (42).

Yaygın olarak kullanılan çekirdek fonksiyonlar aşağıda tanımlanmıştır:

Linear kernel: Linear kernel fonksiyonu veriyi dönüştürmez. Veri setindeki özelliklerin çarpımları olarak ifade edilebilir (45).

$$K(\vec{x}_i, \vec{x}_j) = \vec{x}_i * \vec{x}_j \quad (5.2)$$

Polynomial kernel: Bu kernel Fonksiyonu verinin basitçe linear olmayan dönüşümünü toplar (45).

$$K(\vec{x}_i, \vec{x}_j) = (\vec{x}_i * \vec{x}_j + 1)^d \quad (5.3)$$

Sigmoid kernel: Yapay sinir ağına oldukça paralel olan bir sigmoid fonksiyon kullanarak modeli oluşturur. (45).

$$K(\vec{x}_i, \vec{x}_j) = \tanh(\kappa \vec{x}_i * \vec{x}_j - \delta) \quad (5.4)$$

Radial basis kernel: Radyal tabanlı yapay sinir ağı ile benzer yapıya sahiptir. Çeşitli tipteki datalarda iyi sonuç verir (45)

$$K(\vec{x}_i, \vec{x}_j) = e^{\frac{-\|\vec{x}_i - \vec{x}_j\|^2}{2\sigma^2}} \quad (5.5)$$

5.4. Verilerin Hazırlanması

Bu tez çalışmasında Karadeniz Teknik Üniversitesi Tıp Fakültesi Farabi Hastanesi Acil Tıp Servisine karın ağrısı şikâyetiyle gelen 220 kişinin, 100'ü akut apandisit tanısı olarak opere edilen deney grubu hasta verisi ve 120'si sadece karın ağrısı tanısı olarak taburcu edilen kontrol grubu hasta verisi olarak kullanılmıştır.

DVM modellerinin geliştirilmesinde, RStudio'nun açık kaynak kod ürünü kullanılarak, 100'ü apandisit olan ve 120'si apandisit olmayan toplam 220 hasta verisinin ayrı ayrı %60'ı alınarak 132'si eğitim seti, aynı verinin ayrı ayrı %40'ı alınarak kalan 88'i de test seti olacak biçimde rastgele olarak bölünmüştür.

Veri setindeki parametrelerin seçimi ve laboratuvar test sonuçları uzman hekim danışmanlığında incelenerek elde edilmiştir. Hastalık tanıları, uluslararası sınıflandırılması ICD-10 kodlarına göre belirlenmiştir (46).

6. BULGULAR

6.1. Veri Setinin Analizi

Tanımlayıcı analizler, sürekli değişkenlerde ortalama $\pm$ standart sapma ve kategorik değişkenlerde n (%) kullanılarak verildi.

Çalışma, 95'i kadın 125'i erkek toplam 220 hasta üzerinde gerçekleştirilmiştir. Hastaların 100'ü akut apandisit tanısı alan, 120'si akut apandisit tanısı almayan hastalar olarak gruplandırılmıştır.

Bu çalışmada KTÜ Tıp Fakültesi Farabi Hastanesi Acil Tıp Servisine 2010-2016 yılları arasında karın ağrısı şikayeti ile başvuran ve akut apandisit tanısı alan ve akut apandisit tanısı almayan 220 hasta üzerinden elde edilen cinsiyet, yaş, biyokimya kan testi parametrelerinden, lökosit, trombosit, nötrofil, lenfosit, PDW, CRP, glukoz, BUN, kreatinin, total protein, albumin, total bilirubin, direkt bilirubin, AST, ALT, amilaz değerlerine ait veriler üzerinde lojistik regresyon analizi yapılarak, hastaların akut apandisit riski taşıyıp taşımadıklarına tespit etmede öneme sahip olan kan değerleri belirlenerek açıklayıcı bir model oluşturulmaya çalışılmıştır. Modeli oluşturan bağımsız değişkenler, LR (Likelihood Ratio) geriye doğru adımsal eleme yöntemi kullanılarak SPSS 16 paket programı ile belirlenmiştir. Bu süreç sonrasında, elde edilen anlamlı parametreler yardımıyla R kodlarının geliştirme aracı olarak RStudio'nun açık kaynak kod ürünü kullanılarak bir DVM modeli geliştirilmiş ve hibrit bir karar destek modeli tasarlanmıştır.

6.1.1. Uygulamada Kullanılan Değişkenler

Lojistik regresyon modelinde aşağıda sıralanan bağımlı ve bağımsız değişkenler yer aldı.

Bağımlı değişken;

Akut apandisit: var (1), yok (0) “kategorik”.

Bağımsız değişkenler;

Yaş: Sürekli bir değişken olup, apandisit üzerinde etkili olan risk faktörlerinden biri olabileceği düşünülmüştür.

Cinsiyet: Kesikli bir değişken olup, 1: Erkek, 2: Kadın şeklinde kodlanmıştır.

Lökosit: Sürekli bir değişken olup, vücudu mikroplara, virüslere ve diğer yabancı maddelere karşı koruyan bağışıklıktan sorumlu beyaz kan hücreleridir.

Trombosit: Sürekli bir değişken olup, kanın pıhtılaşma fonksiyonunu sağlayan küçük kan hücreleridir.

Nötrofil: Sürekli bir değişken olup, vücudumuzu bakteri ve mantarlara karşı savunan hücrelerdir.

Lenfosit: Sürekli bir değişkendir. Üç tip lenfosit vardır. B hücreleri (kemik iliği kaynaklı) antikör üretir, hastalık etmenlerine bağlanarak onları yok eder. T hücreleri (thymus bezi kaynaklı) vücudun bağışıklık cevabından sorumludur. Naturel killer hücreler bir virüs veya kanser tarafından etkilenen veya kanserleşme eğilimi gösteren vücut hücrelerini yok eder.

RDW: Sürekli bir değişken olup, eritrositlerin volümlerindeki değişiklikleri gösterir.

MPV: Sürekli bir değişken olup, kandaki trombositlerin ortalama büyüklüğünü gösterir

PDW: Sürekli bir değişken olup, trombosit çaplarının değişkenliğini gösterir (47).

Glukoz: Sürekli bir değişken olup karbonhidrat metabolizmasının değerlendirilmesinde kullanılır.

BUN: Sürekli bir değişken olup, böbrek fonksiyon testlerinden biridir. Protein metabolizmasının değerlendirilmesinde kullanılır.

Kreatin: Sürekli bir değişken olup, böbreğin çalışması hakkında bize bilgi verir. Böbrek fonksiyonlarının değerlendirilmesinde kullanılır.

Total Protein: Sürekli bir değişken olup, böbrek ve karaciğer hastalıklarının takibinde kullanılır. Kronik karaciğer hastalıkları ve yanık gibi durumlarda total protein düzeyi azalır.

Albumin: Sürekli bir değişken olup, karaciğer tarafından sentezlenen ve pek çok iyon, metabolit, ilaçları bağlayan bir proteindir.

Bilirubin: Sürekli bir değişken olup, karaciğer ve safra kesesi fonksiyonlarının değerlendirilmesinde kullanılır.

ALT: Karaciğer fonksiyon testlerinden biridir.

AST: Sürekli bir değişken olup, bütün vücut dokularında bulunmakla beraber, karaciğer, kalp ve iskelet kası en çok bulunduğu hücre içi olarak yer alan bir enzimdir. Herhangi bir nedene bağlı olarak karaciğer hücre zedelenmesi veya hasarı, kalp ve iskelet kası travması, kalp yetmezliği ve ağır egzersiz gibi durumlarda miktarı artar.

Amilaz: Sürekli bir değişken olup, pankreas fonksiyon testlerinden biridir (48).

CRP: Sürekli bir değişken olup, biyokimyasal araştırmalar başlığı altında daha önce açıklanmıştır.

6.2. Lojistik Regresyon Geriye Doğru Adımsal Eleme Modeline Dair Bulgular

Bu çalışmada α anlamlılık düzeyi 0,05 olarak belirlenmiştir. Final modelde yer alması düşünülen aday değişkenlerin seçimi; adımsal seçim metodlarından olabilirlik oran test istatistiğine dayalı geriye doğru eleme yöntemi (backward LR elimination method) kullanılarak yapıldı. Bağımlı değişkene en az etkisi olan değişkenler ($p>0,05$) her adımda sırasıyla çıkarılarak elendi ve final modele ulaşıldı. 13. adımda ulaşılan modelde yer alacak olan bağımsız değişken kümesi Tablo 1’de verilmiştir.

Geriye doğru adımsal eleme yönteminde giriş ve çıkış olasılık değerlerinin 0,05 ve 0,10 olduğu göz önünde bulundurularak, 1. adımında modele tüm değişkenler dahil edilmiştir. Amilaz değişkeninin p değeri en büyük olarak saptanmış olup modele katkısının en az olduğu belirlenerek modelden çıkartılmış ve 2. adıma geçilmiştir. 2. adımda tekrar p değerlerinin karşılaştırılması sonucu RDW değişkeninin diğer değişkenlere göre önemlilik seviyesi az bulunmuş ve bu şekilde tüm değişkenler elemine edilerek bir diğer adıma geçilmiş ve 13. adım sonucunda modelden atılacak değişken kalmamış olup final model oluşturulmuştur.

Tablo 1’de görüldüğü gibi final modelde yer alan; lökosit, CRP, AST, yaş, lenfosit, total protein, cinsiyet ve kreatin değişkenleri sırasıyla modele katkısı yüksek olan değişkenler olarak belirlenmiştir. Daha fazla değişken içermesi modeli daha iyi tanımlamayacağı için p değeri belirlenen olasılık değerinden büyük olan kreatin değişkeni ($p=0,108^*$) modele dahil edilmemiştir. Aynı zamanda bu değişken OR’si (Odds oranı) en düşük olan, yani modele katkısı en az olan değişkendir. Odds oranı, apandisit tanısında değişkenlerin modele etkisinde kaç kat fark oluşturduğunu göstermektedir. OR’si en yüksek olan değişkenlerin lökosit ve CRP olduğu görülmüştür. Buna göre Lökosit ve CRP 1 birim arttığında, apandisit olma olasılığı

ortalama 1 kat kadar (Lökosit OR= 1,162 ve CRP OR=1,094) artmaktadır. Kadınların bağımlı değişken üzerindeki etkisinin erkeklere oranla daha az olduğu gözlenmiştir. Yaş arttıkça apandisit olma olasılığı 0,962 kat azalmaktadır.

Belirlenen bağımsız değişkenlerle kurulan lojistik regresyon modeli aşağıdaki gibidir:

$$\text{Akut apandisit} = 8,465 - 0,039 \text{ yaş} - 0,894 \text{ cinsiyet} + 0,150 \text{ lökosit} - 0,105 \text{ lenfosit} - 0,782 \text{ total protein} - 0,036 \text{ AST} + 0,090 \text{ CRP} \quad (6.1)$$

Tablo 1. Adımsal seçim metotlarından olabilirlik oran test istatistiğine dayalı geriye doğru eleme yöntemi (backward LR elimination method) kullanılarak elde edilen en uygun çok değişkenli lojistik regresyon modeli

Denkleme Alınan Değişkenler							
Adım 13		B	S.H.	Wald	sd	p	OR (95% GA)
	Yaş	-0,039	0,012	10,686	1	0,001	0,962 (0,939-0,984)
	Cinsiyet(1)	-0,894	0,426	4,414	1	0,036	0,409 (0,177-0,942)
	Lökosit	0,150	0,059	6,382	1	0,012	1,162 (1,034-1,306)
	Lenfosit	-0,105	0,026	15,702	1	0,000	0,900 (0,855-0,948)
	Total Protein	-0,782	0,304	6,605	1	0,010	0,458 (0,252-0,831)
	Kreatin	1,057	0,059	2,577	1	0,108*	0,347 (0,096-1,263)
	AST	-0,036	0,014	6,091	1	0,014	0,965 (0,938-0,993)
	CRP	0,090	0,042	4,531	1	0,033	1,094 (1,007-1,189)
	Constant	8,465	2,231	14,401	1	0,000	0,000
- 2 Log olabilirlik değeri: 183,175							

Modelin uygunluğu için, Hosmer-Lemeshow uyum iyiliği testi ile sabit terim hariç tüm katsayıların model üzerinde belirleyici olup olmadığının test edilmesi amaçlanmıştır. Hipotezler aşağıdaki gibidir;

Ho: Parametreler model açısından belirleyicidir.

H₁ : Parametreler model açısından belirleyici değildir.

13. adım için ki kare istatistiği ($\chi^2_h=10,017$ ve $p=0,264$) olarak hesaplanmıştır (Tablo 2). $\chi^2_{hesap} < \chi^2_{tablo}$ ve $p>0,05$ olduğu için Ho hipotezi kabul edilmiş olup, modele dahil edilen değişkenlerin model için uyumlu olduğu ortaya çıkmıştır.

Tablo 2. Hosmer ve Lemeshow test sonuçları

Hosmer Lemeshow Testi			
Adım	Ki-Kare	sd	p
1	12,408	8	0,134
2	12,493	8	0,131
3	15,427	8	0,051
4	11,833	8	0,159
5	11,967	8	0,153
6	11,032	8	0,200
7	11,407	8	0,180
8	11,291	8	0,186
9	17,718	8	0,023
10	5,847	8	0,664
11	6,173	8	0,628
12	7,092	8	0,527
13	10,017	8	0,264

İlk olarak sınıflandırma tablosu incelendiğinde, programın öncelikle tüm hastaları apandisit yok kategorisinde sınıflandırdığı ve bu haliyle doğru sınıflandırma yüzdesinin %54,5 olduğu Tablo 3’te görülmektedir.

Tablo 3. İlk sınıflama tablosu

Sınıflandırma Tablosu^{a,b}				
Gözlem		Tahmin edilen		
		Apandisit		Doğru Sınıflandırma%
		YOK	VAR	
Adım 0	Apandisit	120	0	100
	YOK	100	0	0,0
	VAR			
Toplam Yüzde		54,5		

a. Sabit değer modele dahil edildi.

b. The cut value is ,500

Geriye dönük adımsal eleme yöntemine göre modelin doğru sınıflandırma oranı, yani denklemin doğruluğu %80,0’dır. Denklemin duyarlılığı (apandisit var dediğimizde gerçekten olma oranı) %81,7’dir $\{(98) / (120) = \%81,7\}$. Denklemin özgüllüğü (apandisit yok dediğimizde gerçekten olmama oranı) %78,0’ dir $\{(78) / (100) = \%78,0\}$ (Tablo 4). (Uyum iyiliği katsayısı: Nagelkerke R^2 : 0,562).

Tablo 4. Adımsal sınıflama tablosu

Sınıflandırma Tablosu^a					
Gözlem			Tahmin edilen		
			Apandisit		Doğru Sınıflandırma%
			YOK	VAR	
Adım 1	Apandisit	YOK	98	22	81,7
		VAR	21	79	79,0
	Toplam Yüzde				80,5
Adım 2	Apandisit	YOK	97	23	80,8
		VAR	21	79	79,0
	Toplam Yüzde				80
Adım 3	Apandisit	YOK	99	21	82,5
		VAR	21	79	79,0
	Toplam Yüzde				80,9
Adım 4	Apandisit	YOK	98	22	81,7
		VAR	21	79	79,0
	Toplam Yüzde				80,5
Adım 5	Apandisit	YOK	100	20	83,3
		VAR	22	78	78,0
	Toplam Yüzde				80,9
Adım 6	Apandisit	YOK	100	20	83,3
		VAR	21	79	79,0
	Toplam Yüzde				81,4
Adım 7	Apandisit	YOK	98	22	81,7
		VAR	20	80	80,0
	Toplam Yüzde				80,9
Adım 8	Apandisit	YOK	97	23	80,8
		VAR	18	82	82,0
	Toplam Yüzde				81,4
Adım 9	Apandisit	YOK	98	22	81,7
		VAR	21	79	79,0
	Toplam Yüzde				80,5
Adım 10	Apandisit	YOK	100	20	83,3
		VAR	22	78	78,0
	Toplam Yüzde				80,9
Adım 11	Apandisit	YOK	98	22	81,7
		VAR	23	77	77,0
	Toplam Yüzde				79,5
Adım 12	Apandisit	YOK	97	23	80,8
		VAR	22	78	78,0
	Toplam Yüzde				79,5
Adım 13	Apandisit	YOK	98	22	81,7
		VAR	22	78	78,0
	Toplam Yüzde				80,0

a. The cut value is ,500

Akut apandisit tanısı alan ve almayan hastaların, geriye dönük adimsal eleme yöntemine göre seçilen yaş, cinsiyet, lökosit, lenfosit, total protein, CRP ve AST değerlerine ait bilgileri içeren demografik özellikler, Tablo 5'te ve Tablo 6'da sunulmuştur.

Tablo 5. Akut apandisit tanısı alan hastalarda yaş, lökosit, lenfosit, total protein, AST, CRP değişkenlerinin tanımlayıcı istatistikleri ve cinsiyet değişkeninin dağılımı

Özellik (n = 100)	Ortalama (SS)	Min	Max
yaş	32,94 (15,05)	18	86
lökosit	13,00 (4,14)	4,6	27,3
lenfosit	13,04 (6,93)	2,7	38,4
total protein	6,41 (0,63)	4,5	8,2
AST	23,58 (9,54)	11	56
CRP	5,23 (6,65)	0,01	28

cinsiyet	Frekans	Yüzde (%)	Birikimli Yüzde (%)
erkek	64	64	64
kadın	36	36	100
Toplam	100	100	

Tablo 6. Akut apandisit tanısı almayan hastalarda yaş, lökosit, lenfosit, total protein, AST, CRP değişkenlerinin tanımlayıcı istatistikleri ve cinsiyet değişkeninin dağılımı

Özellik (n = 120)	Ortalama (SS)	Min	Max
yaş	48,30 (8,5)	17	94
lökosit	9,63 (3,42)	2,6	18,51
lenfosit	21,27 (10,41)	4,1	53,2
total protein	6,82 (0,71)	5	8,6
AST	48,69 (86,51)	8	613
CRP	3,15 (4,31)	0,02	19,01

cinsiyet	Frekans	Yüzde (%)	Birikimli Yüzde (%)
erkek	61	50,8	64
kadın	59	49,2	100
Toplam	120	100	

6.3. Destek Vektör Makinesi Modeline Dair Bulgular

Seçilen parametrelere ait 220 veri, R rastgele örnekleme fonksiyonundan faydalanılarak 132 eğitim seti ve 88 test seti olarak ayrılmıştır. Sistem önce eğitim seti ile eğitim kümesini öğrenmiş ve eğitilen sistemin başarısı daha sonra test kümesi üzerinde hesaplanmıştır.

	yas	cinsiyet	loko	lenf	pro_t	ast	crp	tani
1	17	1	11.04	49.8	6.5	27	0.19	2
2	17	1	13.88	10.3	7.7	23	0.55	2
3	18	1	8.9	14.7	6.4	21	1.73	1
4	18	1	17.64	7.9	8.1	23	5.94	1
5	18	2	11.3	10.5	6.8	16	0.11	1
6	19	2	12	27.7	6.7	18	0.02	2
7	19	2	12.6	4.8	5.6	17	13.1	1
8	19	2	18.7	9.4	6.5	17	0.01	1
9	20	1	7.99	38.4	5.4	20	0.52	1
10	20	1	8.3	14.6	6.9	29	0.86	1
11	20	1	13.02	18.1	5.4	20	0.93	1
12	20	1	15.4	9.2	7	20	2.33	1
13	20	1	17.22	17.9	7.7	33	1	2
14	20	2	8.9	23	6.1	13	5.29	2
15	20	2	10.17	13.3	7	13	1.04	1
16	20	2	14.94	11.1	6.5	19	0.75	1
17	21	1	6.96	24.9	5.8	29	2.31	2
18	21	1	8.9	29.4	6.5	17	1.04	2
19	21	1	11.9	5.5	6.4	30	2.15	1
20	21	1	13	6.7	6.6	38	2.13	1
21	21	1	21	11.3	6	31	1.07	1
22	21	2	11.2	12.2	6.2	14	0.87	1
23	22	1	10.69	10.6	5.9	19	4.1	1
24	22	2	8.6	36.2	6.1	11	0.13	2
25	22	2	9.6	9	6.3	20	7.53	1
26	22	2	10.9	18.4	6.7	23	0.28	1
27	23	1	10.8	22.9	6	27	0.12	1
28	23	1	14.01	7.3	6.3	14	8.91	1
29	23	1	15.7	10.9	6.6	24	2.42	1
30	23	1	16.6	12.8	6.1	21	0.07	1

Şekil 7. Train set örneği

	yas	cinsiyet	loko	lenf	pro_t	ast	crp	tani
1	18	1	12.2	11.1	6.4	14	1.38	1
2	18	1	16.77	14.2	6.4	55	0.14	1
3	19	1	6.1	34.5	6.4	13	3.1	2
4	19	1	12.3	21	5.8	17	1.48	1
5	19	1	15.1	7.9	6.5	24	1.19	1
6	19	1	18.24	12.2	6.7	30	8.21	1
7	19	2	9.86	11.6	6.3	13	0.98	1
8	19	2	12.2	6.4	6.2	41	1.05	2
9	20	1	9.3	26.9	7.8	28	0.84	1
10	20	1	10.57	16.9	6.7	33	3.41	2
11	20	1	15.7	4.6	6.4	20	2.98	1
12	20	1	24.23	8	6.1	51	25.3	1
13	20	2	17.97	6.3	5.9	11	1.45	1
14	21	1	6.7	23.3	7	36	0.82	2
15	21	1	17	3.5	6.9	46	0.16	1
16	21	2	6.1	31.3	6.3	15	4.63	2
17	22	1	11.5	21.7	7.2	23	0.98	2
18	22	2	9.6	26.6	6.9	16	1.59	2
19	23	1	7	29.7	6.3	19	1.66	2
20	23	2	4.87	18.1	5.6	13	3.64	1
21	23	2	6.3	18.4	5.5	23	9.54	2
22	23	2	10.74	8.3	4.5	13	0.11	1
23	24	1	15.1	4.8	7.2	26	0.94	1
24	24	1	16.8	8.7	6.7	21	0.15	1
25	24	2	22.5	3.6	6.9	14	28	1
26	25	2	8.7	23	7.5	178	0.56	2
27	26	1	8.4	39.4	7.2	42	0.3	2
28	26	1	17.23	12.8	7.4	37	1.12	1

Şekil 8. Test set örneği

Bu tez çalışmasında 4 farklı DVM modeli geliştirilmiştir. Bu modeller, linear, radyal, polynomial ve sigmoid fonksiyonları kullanılarak elde edilmiştir. Geliştirilen DVM modellerine ait parametre bilgileri aşağıdaki Tablo 7’de verilmiştir.

Tablo 7. DVM kernel fonksiyonları parametre tablosu

	Sigmoid	Radial	Linear	Polynomial
Cost	1	1	1	1
Gamma	0.1428571	0.1428571	0.1428571	0.1428571
Degree	-	-	-	3
Coef.0	0	-	-	0

DVM kernel modelleri için duyarlılık ve özgüllük değerleri aşağıda verilen formüllerle hesaplanmıştır (45).

$$\text{Duyarlılık (Sensitivity)} = \frac{TP}{(TP + FN)} \quad (6.2)$$


$$\text{Özgüllük (Specificity)} = \frac{TN}{(TN + FP)} \quad (6.3)$$

$$\text{Doğruluk (Accuracy)} = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (6.4)$$

Tablo 8. Geliştirilen modellere ait duyarlılık ve özgüllük değerleri

	Duyarlılık	Özgüllük	Doğruluk
Linear	%87	%79	%82
Radial	%80	%84	%83
Sigmoid	%87	%75	%79
Polynomial	%100	%54	%77

Geliştirilen 4 farklı kernel modelinin performansları ROC eğrisi kullanılarak karşılaştırılmıştır.



Şekil 9. Geliştirilen tanı modellerinin performanslarının karşılaştırması

ROC eğrisinin altında kalan alan AUC (Area Under Curve) olarak adlandırılmaktadır. AUC değerinin büyük olması geliştirilen modelin performansının iyi olduğu anlamına gelmektedir. Şekil 9.'da görüldüğü gibi en yüksek AUC değeri, linear kernel fonksiyonu ile elde edilmiştir (AUC = %83.02). Aynı zamanda en yüksek duyarlılık değeri de bu fonksiyona ait olduğundan, akut apandisit hibrit karar destek sistemi için en ideal model olarak linear kernel model seçilmiştir.

Tablo 9. Linear DVM modeli sonuçları ile gerçek sonuçların karşılaştırılması.
TP (True Positive), TN (True Negative), FP (False Positive),
FN (False Negative)

Gerçek Sonuçlar	Modelin Tahmin Sonuçları	
	Apandisit	Apandisit değil
Apandisit	27 (TP)	4 (FN)
Apandisit değil	12 (FP)	45 (TN)

Buna göre, 88 test verisi üzerinde geliştirilen en iyi DVM modeli için, %87 duyarlılık, %79 özgüllük ve %82 doğruluk değerleri elde edilmiştir.

7. TARTIŞMA ve SONUÇ

Günümüzde ne yazık ki akut apandisit olan hastaların bazılarında, cerrahların daha fazla belirtinin oluşması için beklmelerinden dolayı, peritonit ya da birçok komplikasyon oluşmadan önce teşhis yapılamamaktadır. Bu hastalar teşhisi zamanında yapılan hastalara göre daha yüksek ölüm oranına sahiptirler. Bu nedenle akut apandisit zamanında ve doğru teşhisi için gereksiz ve zaman alan prosedürlerden kaçınmak, uygun önlem ve klinik stratejileri belirlemek adına önem arz etmektedir. Ancak bu süreç, anlamlı faktörlerin bulunması ve bunlar arasındaki ilişkinin tanımlanması, hasta geçmişi ve laboratuvar bilgileri gibi rutin olarak kullanılabilir olan birçok parametreye bağlı olması bakımından zor bir süreçtir. Bu amaçla, lojistik regresyon ve makine öğrenmesi yaklaşımlarından DVM yöntemi birlikte kullanılarak hekimlere yardımcı olabilecek bir akut apandisit karar destek sistemi tasarlanmıştır.

KTÜ Farabi Hastanesi Acil Servisine karın ağrısı şikâyetiyle gelen, akut apandisit tanısı alan (n=100) deney grubundaki ve almayan (n=120) kontrol grubundaki toplam 220 hasta verisine lojistik regresyonun adımsal seçim metotlarından, olabilirlik oran test istatistiğine dayalı geriye doğru eleme yöntemi (backward LR elimination method) uygulanmıştır. Bunun sonucunda %82 duyarlılık, %78 özgüllük ve %80 doğruluk değerleri elde edilmiştir. Seçilen parametrelerden, yaş, cinsiyet, lökosit, lenfosit, total protein, CRP ve AST, karar destek sisteminin dizaynında özellikli nitelikler olarak kullanılmıştır. Bu parametrelere ait veri setindeki 220 hastanın 132'si eğitim, 88'i test seti olmak üzere ikiye ayrıldıktan sonra DVM yöntemi yardımı ile hibrit bir karar destek modeli geliştirilmiştir. Geliştirilen DVM modeli için 4 farklı kernel fonksiyonu uygulanmış ve en iyi DVM modelinin linear kernel fonksiyonu olduğu belirlenmiştir. Sonuç olarak 88 test verisi üzerinde %87 duyarlılık, %79 özgüllük ve %82 doğruluk değerleri elde edilerek, ilk etapta lojistik regresyon analizi ile hesaplanan duyarlılık, özgüllük ve doğruluk değerlerinin, hibrit modelin oluşumu ile yükseldiği gözlenmiştir.

Literatürde yapılan benzer bir çalışmada (49) YSA (Yapay Sinir Ağları) yöntemi kullanılarak geliştirilen akut apandisit tanı sisteminde, sadece akut apandisit şüphesiyle ameliyat edilmiş 50 hasta verisi üzerinde eğitim gerçekleşmiş ve eğitim tamamlandıktan sonra, YSA ile sağ kasık ağrısı bulunan ve sonuçları bilinen 20 hastaya ait (daha önce kullanılmamış) veriler kullanılarak doğrulanmış ve ağın optimizasyonu yapılmıştır.

Neticede %96 duyarlılık ve %100 özgüllük değerleri elde edilmiş ve bu sonuçlar Alvarado skor sonuçları ile karşılaştırılmıştır. Yapılan bir başka çalışmada karın ağrısı ile hastaneye başvuran 152 ‘si akut apandisit tanısı alan ve 174’ü taburcu edilen toplam 326 hastaya ait olan veriler ile, tek değişkenli analiz modeli ve wald ileri lojistik regresyon testi ile çok değişkenli analiz modeli kurulmuş ve her iki model için bağımsız değişkenler belirlenmiştir. Sonrasında karar ağacı yöntemiyle bu iki ayrı modele ait olan bağımsız değişkenler yardımıyla karar destek modelleri geliştirilerek karşılaştırılmıştır. Buna göre tek değişkenli analize dayalı model için %82 duyarlılık ve %78 özgüllük, çok değişkenli analize dayalı model için %69 duyarlılık ve %73 özgüllük elde edilmiştir. (50). Bir diğer çalışmada, karın ağrısı olan, 86’sı apandisit teşhisi alan ve 83’ü almayan olmak üzere toplam 169 hastaya ait veriler; sürekli, kategorik ve normalize edilmiş olarak 3 gruba ayrılmış ve bu üç gruba ayrı ayrı lojistik regresyon ve YSA yöntemleri uygulanarak karşılaştırılmışlardır. Lojistik regresyon sonuçlarına göre sürekli, kategorik ve normalize edilmiş veriler için sırasıyla duyarlılık değerleri (%69, %72, %50) ve özgüllük değerleri (%77, %67, %93) olarak elde edilmiştir. YSA sonuçlarına göre sürekli, kategorik ve normalize edilmiş veriler için sırasıyla duyarlılık değerleri (%59, %63, %77) ve özgüllük değerleri (%89, %82, %73) olarak elde edilmiştir (51).

Literatürdeki benzer çalışmalar ile karşılaştırıldığında, bu çalışmada kullanılan parametreler daha farklıdır. Örneğin fizik muayene bulgularından rebound ve karın ağrısının sağ alt kadranda bulunması, apandisit teşhisinde ayırt edici olduğu düşünülen bulgulardan olduğundan diğer çalışmalarda bunlara yer verilirken, bu çalışmada yer verilmemiştir. Bunun nedeni epikriz raporlarında fizik muayene bulgularına ait sağlıklı bilgilerin mevcut olmamasıdır. Epikriz raporlarında fizik muayene bulgularından sağ alt kadranda ağrısının ve rebound’un apandisit tanısı alan hastaların hemen hepsinde pozitif, almayan hastaların ise tamamında negatif olması makine öğrenmesi yöntemini yanıltacağından, bu veriler çalışmaya dahil edilmemiştir. Aynı zamanda akut apandisiti olan hastaların sağ alt kadranda ağrısının, rebound ve hassasiyetinin pozitif olmasına rağmen apandisit teşhisinde yanıltıcı olabilir. Yapılan diğer çalışmalar da göz önünde bulundurulduğunda, fizik muayene ile elde edilen bahsettiğimiz bu kategorik veriler, makine öğrenmesi yöntemine dahil edildiğinde duyarlılığı ve özgüllüğü anlamlı bir şekilde yükselttiğini söyleyebiliriz. Tüm bunlar değerlendirildiğinde yapılan çalışmalar arasında bu çalışma, kullanılan nitelikler ve fiziki muayene bulgularını

içermeyen parametrelerle elde edilen %87 duyarlılık, %79 özgüllük ve %82 doğruluk değerleri ile özgün sayılabilecek olup, ön plana çıkmaktadır.

Geliştirilen akut apandisit hibrit karar destek sistemi ile tıbbi açıdan problem teşkil eden, akut apandisit şüphesi taşıyan hastaları akut karın ağrısı olanlardan ayırt etme durumunu çözümlemede klinisyenlerin ağır iş yükünü azaltabilmek hedeflenmiştir. Akut apandisit konusunda iyi bilinen risk faktörleri haricinde biyokimya kan parametreleri geniş tutularak bunların arasından farklı bir kan parametresinin etkili bulunup bulunamayacağı araştırılmıştır. Buna göre, lojistik regresyon analizi sonuçlarına bakıldığında, akut apandisit teşhisinde anlamlı bulunan rutin kan değerleri dışında AST ve lenfosit değerlerinin de etkili olabileceği gözlenmiştir. Bu parametlere ek olarak elde edilen diğer anlamlı parametreler, DVM modelini oluşturmak için kullanılmış ve neticede hibrit bir karar destek sistemi tasarlanmıştır.

Böylece bu model, hastaların akut apandisit olup olmadığına karar verme sürecinde hekimlere yardımcı olabilecek ve erken tanıda en yüksek doğruluk oranını yakalamak için fayda sağlayabilecektir. Ayrıca şüpheli hastalara yapılan BT çekim sayıları azaltılabilecektir.

Bu ve buna benzer tanı modelleri ilerleyen yıllarda cihazlara modifiye edilmesiyle, akut apandisit veya diğer bazı hastalıklar için bilgisayar destekli yardımcı tanı sistemleri geliştirilebilecektir. Bu çalışmanın, ileride yapılacak olan başka benzer çalışmalara fikir sağlaması ve insanlığa faydalı olması en büyük dileğimizdir.

8. KAYNAKLAR

1. Ohmann C, Franke C, Yang Q (1999) Clinical benefit of a diagnostic score for appendicitis: results of a prospective interventional study. German Study Group of Acute Abdominal Pain. Arch Surg, 134: 993-996.
2. Binnebösel M, Otto J, Stumpf M, Mahnken AH, Gassler N, Schumpelick V (2009). Acute appendicitis. Modern diagnostics-surgical ultrasound. Chirurg, 80: 579–587.
3. Hsieh CH, Lu RH, Lee NH, Chiu WT, Hsu MH, Li YC (2010). Novel solutions for an old disease:Diagnosis of acute appendicitis with random forest, support vector machines, and artificial neural networks. Surgery, 149: 87-93.
4. Ting HW, Wu JT, Chan CL, Lin SL, Chen ML (2010). Decision Model for Acute Appendicitis Treatment With Decision Tree Technology-A Modification of the Alvarado Scoring System. J Chin Med Assoc, 73: 401-406.
5. Prabhudesai SG, Gould S, Rekhraj S, Tekkis PP, Glazer G, Ziprin P (2007). Artificial Neural Networks: Useful Aid in Diagnosing Acute Appendicitis. World J Surg 32: 305-309.
6. Aygün A (2015). Akut Apandisit Erken Tanısında Fizik Muayene, Laboratuvar, Görüntüleme Yöntemlerinin Tanısal Değeri ve Skorelama Sistemlerinin Karşılaştırılması. Uzmanlık tezi, Trakya Üniversitesi Tıp Fakültesi Acil Tıp AD, Edirne.
7. Kılınçer A (2013). Akut Apandisit Ön Tanısı Olan Hastalarda Sağ Alt Kadrana Kompresyon Uygulanarak Elde Olunan Abdomen BT Tetkikinin Tanısal Etkinliğinin Değerlendirilmesi. Uzmanlık tezi, Hacettepe Üniversitesi Tıp Fakültesi Radyoloji AD, Ankara.
8. Young P (2014). Appendicitis and its history. Rev Med Chil, 142: 667-672.
9. Kavic MS, Kavic SM, Kavic SM (2010). Laparoscopic Appendectomy. In: Wetter PA, editor. Prevention and Management of Laparoendoscopic Surgical Complications. 3 ed. Florida: Society of Laparoendoscopic Surgeons, 239-248.

10. Liang MK, Andersson RE, Jaffe BM, Berger DH Brunicardi FC, Andersen DK, Billiar TR, Dunn DL, Hunter JG, Matthews JB (2014) The Appendix. Schwartz's Principles of Surgery. 10 th. ed. New York: McGraw-Hill Education, 1241-1263.
11. Kılınçer A (2013). Akut Apandisit Ön Tanısı Olan Hastalarda Sağ Alt Kadrana Kompresyon Uygulanarak Elde Olunan Abdomen BT Tetkikinin Tanısal Etkinliğinin Değerlendirilmesi. Uzmanlık tezi, Hacettepe Üniversitesi Tıp Fakültesi Radyoloji AD, Ankara.
12. Görmüş C (2007). Akut Apandisit Teşhisinde Alvarado Skoru ile Ultrasonografinin Negatif Laparotomi Oranlarını Düşürmede Etkisi ve Alvarado Skoru sistemine modifikasyon Gerekliliğinin Sorgulanması. Uzmanlık tezi, Haseki Eğitim ve Araştırma Hastanesi, İstanbul.
13. Akut Apandisit (2015) [online].
www.turkcerrahi.com/wp-content/uploads/akut-apandisit.pdf
14. Kalaycı G (2002). Genel Cerrahi Cilt-1. Nobel Tıp Kitabevleri. İstanbul, 260-261
15. Eldrup-Jorgensen J, Hawkins RE, Bredenberg CE (1997). Abdominal vascular catastrophes. Surg Clin North Am. 77: 1305-1320.
16. Albayrak T, Kasım İ, Kahveci R, Şencan İ, Ünsal S, Akça Ö (2012). Bir Apandisit Olgusu. Ankara Medical Journal 12: 153-155
17. Apandisit Nedir? Apandis Hangi, Taraftadır? Belirtileri ve Tedavisi (2015) [online].
<https://www.medikalakademi.com.tr/apandist-ne-tarafta-nerede-apandisitbelirtileri-nelerdir/>
18. Bilgel H (2007). Genel Cerrahi. Avrupa Tıp Kitapçılık Ltd. Sti., No.54, İstanbul, 837-838.
19. Mimoz O, Benoist J.F, Edouard A.R, Assicot M, Bohuon C, Samii K (1998). Procalcitonin and C-reactive protein during the early posttraumatic systemic inflammatory response syndrome. Intensive Care, 24: 185-188.
20. Alican F (1994). Cerrahi Dersleri. Afa Matbaacılık, No.16, İstanbul, 538-540.

21. Yiğitbaş H, İlbar R , Erçetin C , Gülçiçek O , Yavuz E , Solmaz A , Arıcı S , Albayrak R, Çelebi F , Çelik A (2015). Akut Apandisitte Preoperatif USG ile Ölçülen Çap ile Nötrofit/Lökosit Oranı Korelasyonu: 6 Aylık Plot Çalışma. 10. Ulusal Travma ve Acil Cerrahi Kongresi, Antalya, 28 Ekim-1 Kasım 2015, 1-2.
22. Jones K, Pena AA, Dunn EL, Nadalo L, Mangram AJ (2004). Are Negative Appendectomies Still Acceptable? Am J Surg., 188: 748-754.
23. Mariadason JG, Wang WN, Wallack MK, Belmonte A, Matari H (2012). Negative appendectomy rate as a quality metric in the management of appendicitis: impact of computed tomography, Alvarado score and the definition of negative appendectomy. Ann R Coll Surg England, 94: 395-401.
24. Feussner H, Becker V, Bauer M, Kranzfelder M, Schirren R, Luth T (2015). Developments in flexible endoscopic surgery: a review. Clin Exp Gastroenterol, 8: 31-42.
25. Hansson J, Korner U, Khorram-Manesh A, Solberg A, Lundholm K (2009). Randomized clinical trial of antibiotic therapy versus appendectomy as primary treatment of acute appendicitis in unselected patients. The British journal of surgery, 96: 473-81.
26. Başarır, G (1990). Çok Değişkenli Verilerde Ayırsama Sorunu ve Lojistik Regresyon Analizi. Doktora tezi, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 1-52.
27. Kleinbaum, D.G., Klein, M (2002). Logistic Regression, A Self-Learning Text, Second Edition. Springer-Verlag, New York, 4-165.
28. Özdamar K (2004). Paket Programlar ile İstatistiksel Veri Analizi 1. Beşinci Baskı. Kaan Kitabevi, No.9, Eskişehir, 589-592.
29. Bircan H (2004). Lojistik Regresyon Analizi: Tıp Verileri Üzerine Bir Uygulama. Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi 2: 185-208.
30. Kaşko Y (2006). Çoklu Bağlantı Durumunda İkili (Binary) Lojistik Regresyon Modelinde Gerçekleşen I.Tip Hata Ve Testin Gücü. Uzmanlık tezi, Ankara Üniversitesi Fen Bilimleri Enstitüsü Zootehni Anabilim Dalı, Ankara.


31. Budak İ, Şen B, Yıldırım M.Z (2006). Lojistik Regresyon ile Bilgisayar Ağlarında Anomali Tespiti. XV. Akademik Bilişim Konferansı Bildirileri, Antalya, 23-25 Ocak 2013, 813-818.
32. Kartal E (2015). Sınıflandırmaya Dayalı Makine Öğrenmesi Teknikleri Ve Kardiyolojik Risk Değerlendirmesine İlişkin Bir Uygulama. Doktora tezi, İstanbul Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 1-52.
33. Alpaydın E (2014) Introduction to Machine Learning, MIT Press, Cambridge, Massachusetts London, England, 27-31.
34. Harrington P (2012). Machine Learning in Action, 1st Edition, Manning Publications Shelter Island, NY, 3-6.
35. Lantz B (2015). Machine Learning With R. 2nd ed. Packt Publishing. Brimingham: UK, 1-27.
36. Machine Learning Technique (2016) [online].
https://commons.wikimedia.org/wiki/File:Machine_Learning_Technique..JPG.
37. Hal Daumé III. (2012) A Course in Machine Learning [online].
http://ciml.info/dl/v0_8/ciml-v0_8-ch08.pdf
38. Balaban ME, Kartal E (2015). Veri Madenciliği ve Makine Öğrenmesi Temel Algoritmaları ve R Dili ile Uygulamaları. Çağlayan Kitabevi No.3, İstanbul; 15-54.
39. Oğuzlar A (2005). Lojistik Regresyon Analizi Yardımıyla Suçlu Profiline Belirlenmesi. Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi 1: 3-5.
40. Field A (2009). Discovering Statistics Using Spss. Üçüncü Baskı. SAGE Publications Ltd, No.55, London, 212-213.
41. Ayhan S, Erdoğan Ş (2014). Destek Vektör Makineleriyle Sınıflandırma Problemlerinin Çözümü İçin Çekirdek Fonksiyonu Seçimi. Eskişehir Osmangazi Üniversitesi İİBF Dergisi 9: 175- 198.
42. Yılmaz Akşehirli Ö, Ankaralı H, Aydın D, Saraçlı Ö (2013). Tıbbi tahminde alternatif bir yaklaşım: Destek vektör makineleri. Türkiye Klinikleri Journal of Biostatistics 1: 19-28.

43. Kavzoğlu T, Çölkesen İ (2010). Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi. Harita Dergisi 144: 73-82
44. Svm Max Sep Hyperplane With Margin. (2016) [online].
https://commons.wikimedia.org/wiki/File:Svm_max_sep_hyperplane_with_margin.png
45. Lantz B (2015). Machine Learning With R. 2nd ed. Packt Publishing. Brimingham: UK, 1-27.
46. ıcd 10 kodları (2009) [online].
http://www.trabzoneczaciodasi.org.tr/dosyalar/113938HqgICD10_KODLARI.pdf
47. Tam Kan Sayımı Değerleri (2013) [online].
<http://www.doktormurat.net/makale/1102/tam-kan-sayimi-degerleri>
48. Biyokimya Tahlil ve Test Sonuçları (2011) [online].
<http://uzmangruplaboratuvar.com/biyokimya/63-biyokimya-tahlil-ve-test-sonuclari>
49. Demirhan A, Kılıç Y.A, Güler İ H (2010). Tıpta Yapay Zeka Uygulamaları. Yoğun Bakım Dergisi. 9: 31-41.
50. Son CS, Jang BK, Seo ST, Kim MS, Kim MY (2012). A hybrid decision support model to discover informative knowledge in diagnosing acute appendicitis. BMC Medical Informatics and Decision Making, 12:17.
51. Sakai S, Kobayashi K, Toyabe S, Mandai N, Kanda T, Akazawa K (2007). Comparison of the Levels of Accuracy of an Artificial Neural Network Model and a Logistic Regression Model for the Diagnosis of Acute Appendicitis. J Med Syst, 31: 357–364.

9. ETİK KURUL ONAYI

KARAR BİLGİLERİ	Karar No: 12	Tarih: 17/10/2016
	Prof.Dr.Kemal TURHAN'ın sorumluluğunda yürütülmesi planlanan Yük.Lis.Öğr.Tugba KURT'a ait "Akut Apandisit Hibrid Karar Destek Sistemi" başlıklı 2016/157 no.lu ve yukarıda başvuru bilgileri verilen araştırma/tez başvuru dosyası ile ilgili belgeler araştırmanın gerekçe, amaç, yaklaşım ve yöntemleri dikkate alınarak incelenmiş, gerçekleştirilmesinde etik sakınca bulunmadığına; toplantıya katılan etik kurul üyelerinin oy birliği ile karar verilmiştir.	

KTÜ TIP FAKÜLTESİ BİLİMSEL ARAŞTIRMALAR ETİK KURULU KARAR FORMU	
ÇALIŞMA ESASI	Klinik Araştırmalar Hakkında Yönerge, İyi Klinik Uygulamaları Kılavuzu
BASKANIN UNVANI / ADI / SOYADI:	Prof.Dr.Faruk AYDIN

Unvanı/Adı/Soyadı	Uzmanlık Alanı	Kurumu	Cinsiyet		İlişki *		Katılım **		İmza
Prof.Dr.Faruk AYDIN Başkan:	Tıbbi Mikrobiyoloji	KTÜ Tıp Fakültesi	E ☒	K ☐	E ☐	H ☒	E ☒	H ☐	
Prof.Dr.Gamze ÇAN Başkan Yrd.	Halk Sağlığı	KTÜ Tıp Fakültesi	E ☐	K ☒	E ☐	H ☒	E ☒	H ☐	
Prof.Dr.S.Caner KARAHAN Üye:	Tıbbi Biyokimya	KTÜ Tıp Fakültesi	E ☒	K ☐	E ☐	H ☒	E ☐	H ☒	İZİNLI
Prof.Dr.S. Murat KESİM Raporör:	Farmakoloji	KTÜ Tıp Fakültesi	E ☒	K ☐	E ☐	H ☒	E ☒	H ☐	
Prof.Dr.Yılmaz BÜLBÜL Üye:	Göğüs Hastalıkları	KTÜ Tıp Fakültesi	E ☒	K ☐	E ☐	H ☒	E ☐	H ☒	İZİNLI
Doç.Dr. Murat LİVAOĞLU Üye:	Plastik, Rekonş. ve Estetik Cerr.	KTÜ Tıp Fakültesi	E ☒	K ☐	E ☐	H ☒	E ☒	H ☐	
Doç.Dr. Şafak ERSÖZ Üye:	Patoloji	KTÜ Tıp Fakültesi	E ☐	K ☒	E ☐	H ☒	E ☒	H ☐	
Doç.Dr. Evrim Ö. KARAGÖZEL Üye:	Ruh Sağlığı ve Hastalıkları	KTÜ Tıp Fakültesi	E ☐	K ☒	E ☐	H ☒	E ☐	H ☒	İZİNLI
Prof.Dr.Murat ÇAKIR Üye:	Çocuk Sağlığı ve Hastalıkları	KTÜ Tıp Fakültesi	E ☒	K ☐	E ☐	H ☒	E ☒	H ☐	

- * :Araştırma ile İlişki
** :Toplantıda Bulunma

10. ÖZGEÇMİŞ

Soyadı, Adı : KURT, Tuğba

Uyruğu : T.C.

Doğum tarihi ve yeri: 23.03.1984 Hamm

Medeni hali : Evli

E-Posta : ktu.tugbakurt@gmail.com

Yazışma adresi : Karadeniz Teknik Üniversitesi, Farabi Hastanesi, İstatistik Bürosu, Trabzon/Merkez

EĞİTİMBİLGİLERİ

Derece	Mezun Olduğu Kurumun Adı	Mezuniyet Yılı
Yüksek Lisans	Karadeniz Teknik Üniversitesi Sağlık Bilimleri Enstitüsü Biyoistatistik ve Tıp Bilişimi Anabilim Dalı	2014-
Ön Lisans	AÖF İlahiyat	2012 -
Lisans	Ondokuz Mayıs Üniversitesi Fen Edebiyat Fakültesi İstatistik Bölümü	2007
Lise	Pazar 75. Yıl İ.M.K.B Anadolu Lisesi	2002

YABANCI DİL İngilizce