

Destek Vektör Makineleri ve Çok Katmanlı Algılayıcı Ağı ile Prostat Kanseri Ön Teşhisi

Özge DEMİR

YÜKSEK LİSANS TEZİ

İstatistik Anabilim Dalı

Haziran 2022

Prostate Cancer Pre-Diagnosis with Support Vector Machines and Multilayer Perception
Network

Özge DEMİR

MASTER OF SCIENCE THESIS

Department of Statistics

June 2022

Destek Vektör Makineleri ve Çok Katmanlı Algılayıcı Ağı ile Prostat Kanseri Ön Teşhisi

Özge DEMİR

Eskişehir Osmangazi Üniversitesi

Fen Bilimleri Enstitüsü

Lisansüstü Yönetmeliği Uyarınca

İstatistik Anabilim Dalı

Uygulamalı İstatistik Bilim Dalında

YÜKSEK LİSANS TEZİ

Olarak hazırlanmıştır.

Danışman: Doç.Dr. Fatih Çemrek

Haziran 2022

ETİK BEYAN

Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre, Doç.Dr.Fatih Çemrekdanışmanlığında hazırlamış olduğum “Destek Vektör Makineleri ve Çok Katmanlı Algılayıcı Ağı ile Prostat Kanseri Ön Teşhisi” başlıklı YÜKSEK LİSANS tezimin özgün bir çalışma olduğunu; tez çalışmamın tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; tezimde verdiğim bilgileri, verileri akademik ve bilimsel etik ilke ve kurallara uygun olarak elde ettiğimi; tez çalışmamda yararlandığım eserlerin tümüne atıf yaptığımı ve kaynak gösterdiğimi ve bilgi, belge ve sonuçları bilimsel etik ilke ve kurallara göre sunduğumu beyan ederim.

Bu çalışmanın prostat hastalarının verilerinin alınma izni Eskişehir Osmangazi Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurul Başkanlığı 2021-308 karar numarası ile 26.10.2021 tarihli izni ile gerçekleştirilmiştir. 13/06/2022

Özge DEMİR

İmza

ÖZET

Yapay zeka sađlık alanın yeni çözümler getirerek bilgisayar tabanlı teşhis ,tedavi konusunda devrim yapmaktadır.Bu çalışmada klasik istatistiksel yöntemlerin dışına çıkılarak yapay zeka temelli makine öğrenim yöntemleriyle prostat kanseri ön tanısı için sınıflandırma modelleri üretilmiştir.Çalışmada kullanılan veriler Eskişehir Osmangazi Üniversitesi Tıp Fakültesinde 2010 -2021 yılında üroloji kliniğine başvuran hastalardan oluşmaktadır.Retrospektif kohort çalışması şeklinde veri toplanması gerçekleşmiştir.Çalışma veriler birincil ve ikincil olmak üzere iki örneklem üzerinden yürütülmüştür.Uygulamada makine öğrenim yöntemlerinden; yapay sinir ağıları ve destek vektör makineleri kullanılmıştır.Birincil örneklemde en iyi sınıflandırma modeli destek vektör makineleri olup doğruluk %68, duyarlılığı %43,özgüllük %84 ölçülmüştür. İkincil örneklemde de en iyi perfonmasa sahip sınıflandırma modeli destek vektör makineleri olup doğruluk %68, duyarlılığı %43, özgüllük %84 ölçülmüştür. Birden fazla model denenerek en iyi sınıflandırma sonuçlarına ulaşılmıştır.

Anahtar Kelimeler: Destek vektör makineleri, Yapay Sinir Ağları, Prostat Kanseri

SUMMARY

Artificial intelligence revolutionizes computer-based diagnosis and treatment by bringing new solutions to the field of health. In this study, classification models were produced for prostate cancer prediagnosis with artificial intelligence-based machine learning methods by going beyond classical statistical methods. It consists of patients who applied to the urology clinic. Data collection was carried out in the form of a retrospective cohort study. The study was conducted on two samples, primary and secondary. In practice, machine learning methods; Artificial neural networks and support vector machines were used. In the primary sample, the best classification model was support vector machines, with an accuracy of 68%, a sensitivity of 43%, and a specificity of 84%. In the secondary sample, the classification model with the best performance was support vector machines, with an accuracy of 68%, a sensitivity of 43%, and a specificity of 84%. The best classification results were obtained by testing more than one model.

Keywords: Support vector machines, Artificial Neural Networks, Prostate Cancer

İÇİNDEKİLER

ÖZET	vi
SUMMARY	vii
TEŞEKKÜR	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ	xi
ÇİZELGELER DİZİNİ	xii
1. GİRİŞ VE AMAÇ	1
2. LİTERATÜR ARAŞTIRMASI	3
3.1. Yapay Sinir Ağları	20
3.1.1. Yapay sinir ağları kullanım alanları	21
3.1.2. Yapay sinir ağlarının biyolojik ve matematiksel formu	21
3.1.3. İnsan beyni ile sinir ağlarının benzer temel yapıları	22
3.1.4. Sinir hücreleri	23
3.1.5. Yapay sinir hücresini (nöron) oluşturan elamanlar	26
3.1.6. İlk yapay sinir ağ modelleri	34
3.1.6.1. Tek katmanlı algılayıcılar (TKA)	34
3.1.6.2. Basit algılayıcı modeli (Perseptron)	35
3.1.7. Çok katmanlı algılayıcı	37
3.1.7.1. Çok katmanlı ağların mimari yapısı	37
3.1.7.2. Çok katmanlı ağın modeli	39
3.1.7.3. Çok katmanlı ağın öğrenme kuralı	40
3.1.7.4. ÇKA ağının performansının ölçülmesi	43
3.1.7.5. ÇKA ağının öğrenmek yerine ezberlemesi	44
3.1.8. Yapay sinir ağlarında öğrenme metotları	44
3.2. Destek vektör makineleri	48
3.2.1. DVM'nin kullanım alanları	48
3.2.3. İstatistiksel öğrenme teorisi (Vapnik-chervonenkis teorisi)	49
3.2.3.1. VC boyutu	53
3.2.3.2. Yapısal risk minimizasyonu (YRM)	54
3.2.4. DVM sınıflandırma	54

İÇİNDEKİLER (devam)

3.2.4.1. Doğrusal ayrılabilen DVM sınıflandırması	55
3.2.4.2. Doğrusal ayrılmayan DVM sınıflandırması	56
3.2.4.3. Kernel fonksiyon çeşitleri	57
3.2.4.4. Hiperparametrelerin seçimi.....	58
4. BULGULAR VE TARTIŞMA	60
4.1. Prostat	60
4.1.1. Prostat hastalıkları	61
4.1.2 İyi huylu prostat büyümesi	61
4.1.3. Prostat kanseri.....	61
4.1.4. Prostat kanseri tanı ve tedavi	62
4.2. Araştırma Evreni ve Örneklemi	64
4.3. Veri Toplama Tekniği.....	64
4.4. Değişkenler	65
4.5. Uygulama.....	66
4.5.1. Birincil örneklem bulgular.....	66
4.5.1.1. Birincil örneklem betimsel inceleme	66
4.5.1.2. Birincil örneklem yapay sinir ağları sınıflandırma bulguları.....	67
4.5.1.3. Birincil örneklem destek vektör makineleri sınıflandırma bulguları.....	69
4.5.2. İkincil Örneklem Bulgular.....	72
4.5.2.1. İkincil örneklem betimsel inceleme.....	72
4.5.2.2. İkincil örneklem yapay sinir ağları sınıflandırma bulguları	72
4.5.2.3. İkincil örneklem destek vektör makineleri sınıflandırma bulguları...	74
5. SONUÇLAR VE ÖNERİLER.....	77
KAYNAKLAR DİZİNİ.....	80
EK AÇIKLAMALAR	99
Ek Açıklama-A: Etik Kurul İzni.....	99

ŞEKİLLER DİZİNİ

<u>Şekil</u>	<u>Sayfa</u>
3.1. İnsan beyninin fizyolojik yapısı	23
3.2. Biyolojik sinir hücresi	24
3.3. Yapay sinir ağı hücresi	25
3.4. Sigmoid fonksiyonu.....	29
3.5. Tansig fonksiyonu	30
3.6. Doğrusal aktivasyon fonksiyonu	31
3.7. Poslin fonksiyonu	31
3.8. Rampa fonksiyonu	32
3.9. Tek katmanlı algılayıcı modeli (Öztemel, 2006).....	34
3.10. Basit algılayıcı yapısı (Elmas, 2003).....	36
3.11. Çok katmanlı ağ mimarisi	38
3.12. Çok katmanlı ağ hücresi	39
3.13. Çok katmanlı ağ hücresi ağırlıklar fonksiyonel yapısı	40
3.14. Girdi katmanının proses elamanı çıktısı	41
3.15. Öğrenim algoritmaları sınıflandırılması	47
3.16. DVM ‘nin uygulama alanları.....	49
3.17. Model hataları.....	51
3.18. VC boyutu	53
3.19. Optimal sınıflandırma düzlemi.....	55
3.20. Doğrusal olarak ayrılma durumu.....	55
3.21. Doğrusal ayrılamayan verilerin yüksek dereceli nitelik uzayına aktarılması.....	57
4.1. Prostat ve komşu yapılar.....	60
4.2. 2020 yılı kanser vakaları ve dağılımı	62
4.3. Kategorik değişkenlerin frekans grafikleri	67

ÇİZELGELER DİZİNİ

<u>Çizelge</u>	<u>Sayfa</u>
3.1. YSA toplama fonksiyonları	27
3.2. Çekirdek fonksiyonlarının genel gösterimi	58
4.1. Nümerik değişkenlerin betimsel istatistikleri	66
4.2. Yapay Sinir Ağlarında Oluşturulan Parametre Uzayı	68
4.3. En İyi Sınıflandırma Modelinin Parametre Uzayı	68
4.4. En İyi Sınıflandırma Modelinin Hata Matrisi	68
4.5. Yapay Sinir Ağlarında Sınıflandırma Sonuç Metrikleri	69
4.6. DVM Sınıflandırma Hiperparametre Uzayı	69
4.7. DVM Sınıflandırma Üretilen Modeller	70
4.8. DVM Sınıflandırma En İyi Model ve Doğruluk Ölçütü	71
4.9. DVM Sınıflandırma Hata Matrisi	71
4.10. DVM Sınıflandırma Model Sonuç Metrikleri	71
4.11. İkincil Örneklem Betimsel Bulguları	72
4.12. Yapay Sinir Ağlarında Oluşturulan Parametre Uzayı	72
4.13. En İyi Sınıflandırma Modelinin Parametre Uzayı	73
4.14. En İyi Sınıflandırma Modelinin Hata Matrisi	73
4.15. Yapay Sinir Ağlarında Sınıflandırma Sonuç Metrikleri	73
4.16. DVM Sınıflandırma Hiperparametre Uzayı	74
4.17. DVM Sınıflandırma Üretilen Modeller	74
4.18. DVM Sınıflandırma En İyi Model ve Doğruluk Ölçütü	75
4.19. DVM Sınıflandırma Hata Matrisi	75
4.20. DVM Sınıflandırma Model Sonuç Metrikleri	76

1. GİRİŞ VE AMAÇ

Sağlık fiziki ve ruhi olarak iyi olmanın bütünlüğüdür. Sağlıksız bir insan yaşamı düşünülmesi söz konusu bile değildir. Son yıllarda artan teknolojik gelişmeler ile birlikte birçok hastalığın tedavisi ve tanısı mümkün olabilmektedir. Yeni yüzyıl artık multidisiplinler arası çalışmanın önemini bizlere göstermektedir. Sağlıkta yapay zekâ uygulamaları ile birlikte artık bir çok tanı ve tedavi için hekimlerimiz ile multidisipliner çalışmalar yapılabilmektedir.

Sağlık kuruluşlarında sağlık kayıtları ve görüntüleri, toplum verileri, talep verileri ve klinik araştırma verileri gibi birçok geniş veri kümeleri mevcuttur. Yapay zekâ teknolojileri, bu verileri analiz etmek ve insanların kendi başlarına bulamayacakları kalıpları ve iç görüleri ortaya çıkarmak için paha biçilmez bir yöntemdir. Yapay zekâ karmaşık yapıdaki tıbbi verilerinin analizinde insan beynini taklit ederek makine öğrenim algoritmalarını ve yazılımları yöntem olarak kullanmaktadır. Yapay zekâ bu yöntemler ile giriş yapılan karmaşık verileri yaklaşık olarak tahmin edebilmektedir. Sağlıkla ilgili yapay zekâ uygulamalarının temel amacı hastalıkların erken teşhisi ve hasta sonuçları ile hastalığın arasındaki ilişkileri analiz etmektir. Günümüzde sağlık kuruluşları ve bilim insanları tarafından tanı süreçleri, tedavi protokolü ve ilaç geliştirme, kişiye özel tıp, hasta izleme ve bakım, gen düzenleme becerisi, kanser teşhisi gibi uygulamalarda yapay zekâ programları kullanılmaktadır. Sağlık alanında yapay zeka uygulamaları sunan şirketler yatılı hasta sayısını ve kalış süresini azaltarak, personel dağıtımını en uygun hale getirmektedir.

Yapay zekâ klasik istatistiksel yöntemlerden ayıran şey ise veri toplama, işleme ve sonuç olarak hata payı düşük bir çıktı verme yeteneğidir. Yapay zekâ bu performansı makine öğrenim algoritmaları ile gerçekleştirmektedir. Algoritmalar tecrübeleri öğrenebilir ve kendi mantığı oluşturarak kalıp sonuçlar sunabilmektedir. Yüksek performanslı tahmin sonuçları elde edebilmek için makine öğrenimi modellerinin çok büyük miktarlarda girdi verisine ihtiyacı vardır. Yapay zekâ algoritmalarının matematiksel modeli beynin işleyişine

benzer ancak iki şekilde insanlardan farklı özelliđi mevcuttur. Bunlar; algoritmalar gerek ve hedef dođrultusunda algoritma giriř verilerinden ğrenebilmektedir.

Sađlık alanına günden güne artarak difüzyon eden yapay zekâ uygulamaları kanser ön teřhislerinin yapabilme de bize büyük olanaklar sađlamaktadır. Buradaki önemli husus řudur ki kurumlardaki büyük verileri etkin algoritmalarla dođru şekilde kullanılmasıdır.

Bu alıřmada 2012-2021 yılları arasında Eskiřehir Osmangazi Üniversitesi Tıp Fakóltesi Eđitim ve Arařtırma Hastanesi Üroloji polikliniđine prostat rahatsızlıđı sebebiyle bařvuran hastalara iliřkin prostat kanseri ön tanı modelinin, yapay zeka uygulamasıyla, geliřtirilmesi amalanmıřtır. alıřmanın uygulama kısmında yapay zekâ makine ğrenim yöntemlerinden yapay sinir ađları ve destek vektör makineleri yöntemleri kullanılarak ön tanı için sınıflandırma modelleri kurulmuřtur.

2. LİTERATÜR ARAŞTIRMASI

Crawford vd.(2000), "Klinik Lokalize Prostat Karsinomu Olan Erkeklerde Lenf Nodu Yayılımını Öngörmek için Yapay Zekâ Teknolojisinin Kullanımı" adlı çalışmalarında lenf nodu yayılımı bakımından düşük risk altındaki prostat karsinomu hastalarını belirlemek için yapay zekâ yöntemleri değerlendirilmiştir. 4133 hastanın Gleason toplamı ve prostat spesifik antijen (PSA) seviyesi basit karar ağacı yöntemiyle düşük riskli eşik değerleri üretilmiş. Klinik TNM (Kötü huylu tümöre bağlı kanserin sınıflandırılması için dünya çapındaki kullanılan standarttır.) için düşük risk sınır değeri elde edilebilmesi için deneysel analiz yapılmış. Bu eşik değerler daha sonra ayrı kurumlardan 2 ek, daha küçük veri tabanına (sırasıyla 227 ve 330 hasta) uygulandı. Karar ağacından elde edilen güven sınır değerleri daha büyük veri tabanına uygulandığında, hastaların %44'ü lenf nodu metastazı açısından düşük risk altında olarak sınıflandırılmıştır (%0,8 yanlış negatif oranı). Aynı güven sınır değerleri daha küçük veri tabanlarına uygulandıklarında ise hastaların %11 ila 43'ü düşük riskli olarak sınıflandırılmış ve yanlış negatif oranı %0,0 ila 0,7 arasında bulunmuştur. Çalışma sonucunda basit bir karar ağacı algoritmasıyla daha büyük hasta kitlesi ile çalışıldığında gereksiz lenf nodu diseksiyonlarının engellenebilir olduğu gözükmiştir.

Churilov vd.(2004),sağlık alanında gelecekteki klinik tedavi kararlarını veri madenciliği karar algoritmalarının desteklemek amacıyla prostat kanseri hastalarını homojen sınıflara ayırma üzerinde çalışma yapmışlardır. Küme analizi tabanlı model önerilmiş ve bu modeli çözmek için düzgün olmayan konveks olmayan optimizasyon tekniklerinden yararlanmışlardır. Optimizasyon temelli yaklaşım kullanılmasının, klinik karar vermeyi geliştirmek için etkin bir şekilde kullanılabilecek önemli miktarda yeni bilginin üretilmesine yol açabileceği konusunda katkıda bulunulmuştur.

Barlow vd.(2019) , çalışmalarında Ulusal Kanser Enstitüsü'nün Prostat, Akciğer, Kolorektal ve Yumurtalık Kanser Tarama Denemesinin tarama kolundan 35.875 prostat kanseri hastalarından oluşan bir veri seti SVM ve MOTE örnekleme yöntemi ve makine öğrenimi için AdaBoost kullanılarak kümeleme işlemi yapmışlardır. Verileri prostat

kanseri olmayan örneklere, düşük riskli prostat kanserli örneklere ve yüksek riskli prostat kanserli örneklere ayırmışlar. Daha sonra PSA, yaş, BMI değişim hızı ve ırka göre filtrelemenin bu modelin doğruluğuna katkısını değerlendirilmiş. Oluşturulmuş modele ilişkin filtreleme sonucunda PSA değişim oranı ve yaşın dâhil edilmesinin modelin eğrisi altındaki alanı (AUC) %6,8 artırdığını, buna karşın BMI ve ırkın minimal bir etkiye sahip olduğunu belirlemişler.

Keles vd.(2007),prostat kanseri tıbbi teşhisinde NEFCLASS-J ile tıbbi veri analizinin ne kadar iyi yapılabileceğini ve seçilen parametrelerin sınıflandırıcı performansları üzerinde ne gibi etkileri olduğu konusunda çalışma yürütmüşlerdir. Tıbbi veriler, gerçek prostat kanseri ve iyi huylu prostat hiperplazisi olan hastalardan elde etmişlerdir. Kullanılan verilere uygun sınıflandırıcının yüksek performansının oluşturulabilmesi için öncelikle üyelik tipine ve bulanık küme sayısına iyi karar verilmesi ve ardından doğrulama işleminin yapılması gerektiğini göstermişler. Sınıflandırma da iyi bir performans ile çalışan sınıflandırıcı seçilmiş ve sınıflandırıcıyı geliştirmek için çeşitli parametreler üzerinde durulmuş. Prostat kanseri veya prostat hiperplazisi olan hastaların teşhisi için bir öngörü sunulmuştur.

Avşar (2009), tezinde EEG işaretleri epilepsi tespiti için alınmış makine öğrenme tekniklerinden tek-sınıf destek vektör makineleri kullanmıştır. mRMR yöntemiyle bulunan öznitelikler kullanılarak tek-sınıf DVM sınıflandırıcısı eğimi yapılmış. Performans ölçütü olarak ROC eğrisi AUC değeri alınmıştır. , bu üç durumdan (Tüm öznitelikler, Temel Bileşenler Analizi, mRMR) mRMR öznitelik seçiminin uygun öznitelik sayısı ile tüm öznitelikler ve Temel Bileşenler Analizine göre daha iyi sonuç verdiği belirtilmiştir.

Saritaş vd. (2010),çalışmada hastaların serbest prostat spesifik antijen, total prostat spesifik antijen ve yaş verilerini kullanarak kanser olup olmadığını gösteren prognostik bir sonuç veren yapay bir sinir ağı tasarımı yapmışlardır. Bahsedilen sistemin tasarımında biyopsi sonrası kesin kanser teşhisi konan 121 hastanın verileri kullanılmış. Hastaların kesin tanı sonuçları ve yapılan YSA sonuçları, konfüzyon matrisi ve ROC analizleri kullanılarak analiz edildi. Bu analizlere dayalı olarak uygulanan YSA sonucunda hastalık prognozu için sırasıyla %94,11 ve geçerlilik için %94,44 başarı oranları elde etmişlerdir.

Erdal vd. (2011), destek vektör makineleri tekniği ile tahmine dayalı modellemeyi ele almıştır. Veri seti Türkiye’de Ocak.1991ve Ağustos.2008 dönemlerine ait 21 ana imalat sanayi için sektörel kapasite kullanım oranları tahmini yapılmıştır.Yöntem olarak makine öğrenim yöntemlerinden destek vektör makineleri kullanılmış ve tahminleme başarıları paylaşılmıştır.

Coudert vd.(2012),çalışmalarında prostat kanserinin patolojik evre tahmini için hem öngörücü yöntemleri hem de öngörücü değişkenleri üzerinde durulmuştur. İngiliz Ürolojik Cerrahlar Birliği (BAUS) tarafından toplanılmış ve İngiltere genelinde 57 merkezde prostatektomi ile tedavi edilen 1700'den fazla hastaların verileri kullanılmıştır. LR, yapay sinir ağları ve Bayes ağları (BN'ler) dahil olmak üzere bir dizi sınıflandırıcı aynı verilere uygulandı ve ROC eğrisi (AUC) altındaki alan kullanılarak birbirleriyle karşılaştırılmıştır. Sınıflandırma sonucunda BN'lerin genellikle diğer yöntemlerden daha iyi performans gösterdiği ortaya çıkmıştır.

Nitze vd. (2012),tarımsal ürünlerin sınıflandırmak amacıyla makine öğrenme yöntemlerinden yararlanmışlardır .2009 büyüme sezonunda çoklu uydu görüntüleri ile Kanada Prairies'de bulunan 500'den fazla ürün alanından oluşan bir veri kümesini tabakalı rastgele örnekleme tekniği ile önce sınıflandırmışlardır. Ve daha sonra verileri destek vektör makineleri ,yapay Sinir Ağları ve Rastgele Orman (RF) ile geleneksel sınıflandırma tekniğiyle Maksimum Olabilirlik (ML) karşılaştırmalar yapılmıştır. Radyal tabanlı veya polinom çekirdekleri kullanan Destek Vektör Makinesi sınıflandırıcıları, genel doğruluk ve sağlamlık açısından YSA ve RF'ye göre üstün sonuçlar göstermiş ancak ML daha düşük doğruluklar ve daha yüksek değişkenlik olduğu görülmüştür.

Özgür vd. (2012), Saldırı Tespit Sistemlerine (STS) Makine Öğrenme yöntemlerinin bu alanda etkinliğini test edilmesi amacıyla 4 tekniğin (Karar Ağaçları, Yapay Sinir Ağları, Destek Vektör Makineleri ve AdaBoost algoritması) başarısına bakılmıştır. Bu sebeple KDD99 veri seti kullanmışlardır. Veri seti üzerinde Weka Makine Öğrenmesi Tezgâhı kullanılarak 4 tekniğin performansı karşılaştırılmıştır.

Kuzey (2012), bilgi çalışanları üzerinde 2011 yılında 564 anket yapılmış anket yoluyla aldıkları bilgi kayıtları üzerine DVM ve Karar ağaçları modelleri uygulayarak modellerin performansları değişik yollarla ile karşılaştırmışlardır. Analiz sonucunda DVM ile cart modelinin doğruluk oranı diğer modelere göre yüksek çıkmıştır.

Kartal (2012), makine öğrenimi yöntemlerinin envanter sınıflandırmada kullanımı incelenmiştir. Çalışmalarında Destek Vektör Makineleri (DVM) olmak üzere sezgisel sınıflandırıcıların performansı karşılaştırılmıştır. Veri olarak büyük ölçekli bir Türk otomotiv şirketinin endüstriyel malzemeler kategorisindeki envanter ele alınmıştır. Elde edilen veriler YSA, Bayesli sınıflandırıcı ve Destek Vektör Makineleri ile üç ayrı sınıflandırma yapılmış ve yöntemlerin performansı karşılaştırılmıştır. Bu üç yöntemin karşılaştırılması sonucunda en iyi yöntem DVM seçilmiş ve ilgili model geliştirilmiştir.

Karagül (2013) ,İstanbul Menkul Kıymetler Borsası 100 (IMKB-100) içinde gıda, tekstil ve çimento sektörlerinde faaliyet gösteren 42 şirketin 10 adet finansal oranın 2006-2011 yılları arasındaki ortalama değerleri finansal oranlara bağlı olarak üç sınıfa ayrılmıştır. Söz edilen oranlar kümeleme analizi sonuçları ile veri kümesi oluşturmuşlardır. Destek Vektör Makineleri (DVM) tekniği ile yapılan sınıflandırma çalışması %95,23 oranında doğruluğa sahiptir. Sınıflandırma çalışmasında 12 adet model üretilmiştir. Bu modellerden giriş duyarlılık analizi yapılarak bu 10 orandan en etkin olan 4 oran tespit edilmiştir. Dört oran en etkisizden en etkili olan faktöre doğru modelden sıra ile çıkarılarak yeni en etkili DVM modeli üzerinde çalışılmıştır. Ulaşılan sonuç en iyi performans modeli ilk 3 faktöre bağlı olan model olarak bulunmuş.

Castanho vd. (2013) çalışmalarında sınırlı veya sınırlı kanserli hastaların sınıflandırılmasında bazı bulanık uzman sistemlerin performansı üzerine çalışılmıştır. Genetik algoritma ile uyarlanmış bulanık kurallar ve üyelik fonksiyonları ile bir bulanık uzman sistem geliştirmişler. Kullanılan yaklaşım sonucunda diğer çalışmalar ile karşılaştırıldığında daha iyi bir kesinliğe ulaşıldığı belirtilmiştir.

Kaya vd.(2013), prostat spesifik antijeni (PSA) değerleri ile prostat kanseri olan ve prostat kanseri olmayan hastaların yapay sinir ağları (YSA) tekniği ile tahmin edilmesi

üzerinde çalışmışlardır. Fırat Üniversitesi Tıp Fakültesi Üroloji Anabilim Dalı Polikliniği'nden alınan 203 vaka ile çalışılmıştır. YSA modelleri, ileri beslemeli geriye yayımlı ağ kullanılmış ve tahminde bulunmuşlar. YSA tahmin modellerinde, yordamlayıcı katsayısı (R^2) ve en küçük hata kareleri ortalaması (MSE) sırasıyla; 0.75 ve 0.07 olarak bulmuşlardır.

Zupan vd. (2014), tekrar eden prostat kanseri vakaları üzerinde çalışılmıştır. Nüks eden prostat kanseri vakalarını belli parametreleri ağırlandırarak makine öğrenme yöntemlerini kullanmışlardır. Yeni istatistiksel yöntemlerden performans anlamında daha iyi olduğunu sonucuna varmışlardır. Hastalığın nüks modellerine uygun şekilde modellenen veriler içindeki ilişkilere daha fazla iç gözü sağlayabileceğini belirtilmiştir.

Kaya vd. (2014), web uygulamaları ve kullanıcı sayısı, veri güvenliği açısından bazı riskler değerlendirilmiş saldırı tespit sistemlerinde uygulanan makine öğrenme teknikleri, kullanılan sınıflandırıcılar ve çözümlenen başarılarla bakılmıştır. 2007-2013 yılları arasında SCI, SCI Expanded ve EBSCO indekslerince taranan ulusal ve uluslararası dergilerde yayınlanmış 65 makale incelenmiş, sonuçlara karşılaştırılmalı olarak yer verilmiştir.

Ayhan vd.(2014), makine öğrenme yöntemlerinden destek vektör makinelerinin sınıflandırma problemleri için kernel (çekirdek) seçimi üzerine çalışmışlardır. Çekirdek fonksiyon seçim süreci rasgele bölük deney tasarımı temeli esas alınmıştır. Çekirdek fonksiyonu seçerken ise tek yönlü varyans analizi (Univariate ANOVA) uygulanmıştır. Performans değerlendirmesi sonucunda radyal tabanlı fonksiyonun başarılı olduğunu ispatlamışlardır.

Gürsoy vd.(2014), çalışmalarında GARCH tipi modellerden GARCH(1,1), EGARCH(1,1) ve GJR-GARCH(1,1) modelleri ile Destek Vektör Makineleri (DVM) yakınsaması ele alınmıştır. 04.01.2007 – 31.12.2012 dönemine ilişkin olarak günlük İMKB Ulusal 100 endeksi-kapanış fiyatları kullanılmış ve modellerin klasik çözümü ile DVM çözümlerinin tahminleme performansları karşılaştırılmıştır. DVM temelli karma GARCH modellerinin iyi bir performans sergilediğini belirtmişlerdir.

Aytuğ vd. (2015) görüş madenciliğinin bir sınıflandırma modeli olarak ele alınacağını öne sürmüşlerdir. Makine öğrenmesi algoritmalarının literatür araştırmalarında genellikle görüş sınıflandırma amacıyla kullanıldığı gösterilmiş. Aynı zamanda makine öğrenmesi tekniklerinin güçlü ve zayıf yönlerinde yer verilmiştir.

Akben vd.(2015), çalışmalarında migren hastalarının teşhisinde kullanılan biyomedikal malzemelerden bahsedilmiş ve daha kolay tespit yapılabilmesi çözüm aranmıştır. Bu sebeple sağlıklı ve migren hastalarından alınan EEG işaretleri Öz bağlantı ile metot olan (AR) Burg metodu ve Alt Uzay temelli metot olan MUSIC metodu ile frekans eksenine dönüştürmüşler. Ulaşılan sonuçlar ile güç spektral yoğunluk grafikleri ile karşılaştırılmış ve destek vektör makinesi sınıflandırma metoduyla bu karşılaştırma sonuçları ele alınmıştır. Performansa göre hangi frekans-genlik oluşturma tekniğinin migren hastalığının saptamasında daha iyi olduğunu belirlemişlerdir.

Akgün (2016), akan veri analizi sınıflandırma LR ve DVM yöntemlerini kullanmışlardır. Büyük akan veri problemleri çözümünde kullanılan Apache Spark Streaming teknolojisi ile DVM sınıflandırma tekniğini geliştirmişler ve geliştirdikleri DVM çözümünü LR tekniği ile karşılaştırılması yapılmıştır. Sahtecilik veri kümesi üzerinde çalışmışlardır. DVM ve LR yöntemlerinin performansları için ROC değerleri ile çalışma sürelerine bakılmıştır. Apache Spark Streaming teknolojisi ile mevcut akan LR yöntemi ile sonuçlarını karşılatırmış ve geliştirdiği DVM tekniğinin kullanılan veri sınıfları üzerinde daha başarılı olduğu sonuçlanmıştır. Süreç bakımından ise geliştirdikleri akan DVM tekniğinin dağıtık bilgisayarlara getirdiği ağırlık incelendiğinde mevcut akan LR yöntemi ile benzer sonuçlar elde edildiği belirtilmiştir.

Cosma vd.(2016), prostat kanseri öngörü modellemeye uygulanmış olan hesaplamalı zeka yaklaşımları üzerine son zamanlarda yapılan bir araştırmaları ve dikkat edilmesi gereken zorluklar üzerinde çalışma sunmuşlardır. Metasezgisel optimizasyon algoritmalarını (doğadan ilham alan algoritmalar olarak da bilinir), Yapay Sinir Ağlarını, Derin Öğrenmeyi, Bulanık tabanlı yaklaşımları ve bunların melezlerini ve ayrıca Bayes temelli yaklaşımları, Markov modelleri içeren geniş bir hesaplama zekası tekniklerini

incelemişlerdir. Karınca Kolonisi Optimizasyonu, Parçacık Sürü Optimizasyonu ve Yapay Bağışıklık Ağı gibi metasezgisel optimizasyon yaklaşımları, prostat kanseri tahmin modellerinin performansını optimize etmek için kullanılmış ve bu yöntemlerin uygunluğu sonucunda tartışılmıştır.

İnce vd.(2016) tedarikçi kredi endeksini tahmin etmek üzere, destek vektör regresyon (DVR) ve ikiz destek vektör regresyon (İDVR) yöntemlerini kullanmışlardır. DVR ve İDVR daha küçük örneklerle analiz yapmaya uyarlanmıştır. DVR ve İDVR yöntemlerinin yaptığı tahminlerin kesinlikleri karşılaştırılmıştır. Örneklerin analizi sonucunda İDVR yönteminin DVR yöntemine daha başarılı olduğu gözlenmiştir.

Akdağ (2016), Diyarbakır kent merkezinde içme suyu talebini Yapay Sinir Ağları ve klasik zaman serisi analizi tekniği olan Winters'in Mevsimsel Üstel Düzeltme Yöntemi ve Box-Jenkins Tekniği kullanarak tahmin etmiştir. Sözü geçen yöntemlerin tahmin değerlerinin performansları, Verimlilik, Ortalama Hata Kareleri, Ortalama Hata Kareleri Kökü, Ortalama Mutlak Yüzde Hata ölçütleri bakımından karşılaştırılmıştır. Yapay Sinir Ağlarının diğer yöntemlere göre, tüm performans ölçütleri bakımından daha iyi tahmin sonuçları verdiği belirlenmiştir.

Kaynar (2017), müşteri kaybı analizi temelli bir çalışma yürütmüşler.4667 müşteri bahsi geçen müşterilerin her birinin 21 adet işlem kaydına ait nitelikler ile müşterilerin ayrılıp ayrılmadığı sınıf bilgisi içeren veri seti ile çalışmışlardır. Telekomünikasyon sektöründe müşteri kaybını tahmin etmek için makine öğrenme yöntemlerinden Destek Vektör Makineleri (DVM), Yapay Sinir Ağları (YSA) ve Naive Bayes (NB) gibi çeşitli sınıflama teknikleri kullanılmıştır. Belirtilen tekniklerin karşılaştırılması sonucunda yapay sinir ağları, diğer makine öğrenmesi yöntemlerine göre daha başarılı olduğu görülmüştür.

Demirbulut vd.(2017), kredi skorlama çalışmalarında makine öğrenme algoritmaları ve istatistiksel teknikler üzerine bir çalışma yapmışlardır. Kredi skorlama sistemlerinde kullanılabilecek farklı algoritmalara değinilmiştir. Kredi talebinde bulunan müşterilerin kredi isteğinin onaylanması veya ret kararının verilmesini kolaylaştıracak bir sistem geliştirmişler. Geliştirdikleri sistemde K En Yakın Komşu (KNN), C4.5 Ağacı,

Yapay Sinir Ağı, Destek Vektör Makinesi (SVM), Lojistik Regresyon, Probit Regresyon, Poisson Regresyon ve Genelleştirilmiş Katkı Modeli (GAM) teknikleri karşılaştırılmasını sunmuşlar. Sözü geçen algoritmalarından edinilen sonuçlar ile müşterinin kredi skorunun tespit edilmesine olanak sağlanmışlardır.

Tirumala vd. (2017) prostat kanseri gen ekspresyonu veri kümelerini analiz kullanmışlardır. 102 adet numune (50 adet normal ve 52 adet tümör) için 12.533'ten fazla öznitelikten oluşan köklü bir prostat kanseri gen ekspresyonu veri setinde önemli (etkili) öznitelikleri belirlemeye çalışmışlardır. Öznitelikleri sınıflandırmak üzere farklı istatistiksel ve yapay zekâ (AI) tabanlı özellik seçim yöntemi, yapay sinir ağları, Naive Bayes, AdaBoost ve J48 algoritmalarını kullanmışlardır. Sınıflandırmalar sonucunda YSA'lar SVM öznitelik seçimi ile %95,1'lik bir doğruluk elde edilmiştir (102 örnekten 96'sını doğru bir şekilde tahmin ederek). Ulusal Biyoteknoloji Bilgi Merkezi veri tabanı araştırılarak, SVM öznitelik seçimine ait 24 öznitelikten 21'inin (%87,5) kanser/tümör referansına sahip olduğu ve böylece öznitelik seçimi ile biyolojik akla yakınlık arasında bir bağlantı kurulduğu sonucuna varılmıştır. Sınıflandırmaların ise etkisinin prostat kanserini öngörme arasındaki farklılıkları ve benzerlikler olduğu savunulmuştur.

Filiz vd. (2017), BIST-50 endeksinin değişimine etki eden faktörlerden DAX, FTSE, S&P 500, BISTBANK, BISTMALI, BISTSINAI, GOLDINDEX, Euro/Dolar Paritesi, Ham Petrol Fiyatı ve Faiz oranları verilerini sınıflandırmak için makine öğrenmesi tekniklerinden, k en yakın komşu algoritması (k-NN), Naive (basit) Bayes sınıflandırıcısı, C4.5 sınıflandırma algoritması ve yapay sinir ağları (YSA) uygulanmıştır. Gerçekleştirilen analizler sonucunda %92.71 oranı ile C4.5 sınıflandırma algoritması doğru sınıflandırmada diğer makine öğrenim algoritmalarına göre daha iyi performans gösterdiği gözlemlenmiştir.

Onan vd.(2017), Türkçe Twitter mesajlarının sınıflandırılması konusunda çalışmışlar üç temel makine öğrenmesi sınıflandırıcısı (Naive Bayes algoritması, destek vektör makineleri, lojistik regresyon) kullanmışlardır. Metin temsiliinde, farklı öznitelik temsili (1-gram, 2-gram ve 3-gram) ve bu öznitelik temsilleri ile elde edilen farklı öznitelik setleri üzerinde durulmuştur.

Taş vd.(2017), büyük boyutlu gen örnekleri sınıflandırma problemleri üzerine çalışılmıştır. Teknik olarak, öncelikle ikili/çoklu sınıflandırma problemlerini ayrı ayrı eşli ikili sınıflandırma problemlerine çeviren bir sınıflandırma yöntemi geliştirmişlerdir. Yapmış oldukları sınıflandırıcı gerçek problemlerin çoğunluğunda diğer popüler sınıflandırıcılara göre oldukça iyi çalıştığı belirtilmiştir.

Namlı vd. (2017), film endüstrisindeki gişe hasılatı tahmini için geleneksel makine öğrenme yöntemleri olan yapay sinir ağları, destek vektör makineleri algoritmalarından; karar ağaçları algoritmalarından ise rastgele ağaç, rastgele orman ve C4.5 algoritmalarını kullanmışlardır. Belirtilen algoritmalar ve topluluk algoritmalarından birisi olan torbalama algoritması kullanılmış ve melez bir model oluşturulmuştur. Tahmin modelleri doğru sınıflandırma yüzdesi, kappa istatistiği, ROC alanı ile karşılaştırmışlar ve rastgele orman-torbalama, yapay sinir ağları-torbalama melez metotlarının tüm modeller arasında en başarılı modeller olarak gözlenmiştir.

Güldoğan vd. (2017), İnönü Üniversitesi Turgut Özal Tıp Merkezi Kardiyoloji Anabilim Dalı için geliştirilen veri tabanından geriye yönelik (retrospektif) Akut Koroner Sendromlu hastalarda tip 2 diabetes mellitus ile farklı demografik ve klinik değişkenler kullanılarak çeşitli çekirdek fonksiyonları ile oluşturulan destek vektör makinesi modelleri uygulamışlardır. Oluşturulan destek vektör makinesi modellerinin, Akut Koroner Sendromlu hastalarda diabetes mellitusu sınıflandırma performansları karşılaştırılmış ve özetlenmiştir. İncelenen çeşitli çekirdek fonksiyonları yardımı ile oluşturulan modeller için performans ölçütleri dikkate alınarak, en iyi sınıflama performansının Laplace Destek Vektör Makinesi modelinde ortaya çıktığı belirtilmiştir.

Demolli vd. (2019), 2013-2017 yılları arasında Niğde bölgesine ait sıcaklık ve güneşlenme şiddeti verileri ile gelecek yıla ait güneş enerjisi potansiyeli makine öğrenmesi tahmin modeli üzerinde çalışmışlardır. Makine öğrenmesi algoritmalarından kNN, Destek Vektör Makinesi ve Lasso Regresyon algoritmaları kullanmışlardır. Makine öğrenim algoritmalarının performansları karşılaştırıldığında en iyi performans sonucu $0.997 R^2$ skoru ile destek vektör makinesi algoritması seçilmiştir.

Cuocolo vd.(2019), prostat manyetik rezonans görüntülemeye (MRI) odaklanan radyolojide yakın zamanda önerilen makine öğrenimi (ML) uygulamalarının bir liste ve özeti sunmak için çalışmışlardır. Makine öğrenimi ve klasik kural tabanlı algoritmalar arasındaki farkı ve denetimli, denetimsiz ve pekiştirmeli öğrenme arasındaki farkı tanımladıktan sonra, insan sinir ağlarını taklit eden yapısı ve kendi yapısını içeren yeni bir makine öğrenimi türü olan derin öğrenmenin (DL) özelliklerini açıklamışlardır. ML ve DL'yi prostat MRG'sine uygulamak için farklılıklar vurgulamışlar. Sonuçlar umut vericidir ancak klinik uygulanabilirlik, tarayıcı satıcıları, saha güçleri ve kurumlar arasında hala daha sağlam doğrulama gerektirir.

Che vd.(2019), ürolojide yapay zeka ve yapay sinir ağları uygulamasına ilişkin ilgili çalışmaları saptamak için Medline, PubMed, Cochrane Database ve Embase taranarak sistematik olmayan bir literatür incelemesini gerçekleştirmişlerdir. Prostat kanserine odaklanan prostat biyopsi sonuçlarının tahmini için yapay zekâ uygulamalarının olduğu, mesane kanseri için nüksüz olasılık tahmini ve tanısal değerlendirme makine öğrenme algoritmalarının analiz edilmiştir. Ve böbrek ve testis kanseri için, evreleme ve hastalıkların nüksünün öngörülmesi için anekdot deneyimler rapor edilmiştir.

Chen vd. (2019), ürolojideki yapay zeka uygulamaları literatür yazması yapmışlardır. Bunun için 231 makale incelemesi yapılmıştır. İncelenen makalelerde kanser tespitini veya sonuç tahminini iyileştirmek veya otomatikleştirmek için radyomik görüntüleme veya ultrasonik eko verilerini kullanmak, patoloji slaytlarında kanser tespitini otomatikleştirmek için sayısallaştırılmış doku örneği görüntülerini kullanmak ve yardımcı olmak için hasta klinik verilerini, biyobelirteçleri veya gen ifadesini birleştirerek tahmin değerleri oluşturdukları belirtilmiştir. Geleneksel istatistiksel analizle karşılaştırıldığında, çalışmaların %71,8'i yapay zekânın tanı ve sonuç tahmininde üstün olduğu sonucuna erişmişler.

Nitta vd. (2019), prostat kanseri için prostat spesifik antijen (PSA) tabanlı PSA taramasından doğruluğu artırmak için makine öğrenimi yöntemlerini (MLM'ler) kullanarak etkili bir istatistiksel model oluşturmak üzerine çalışmışlardır. Prostat biyopsisi yapılan 512 hastadan son 2 yılda PSA seviyesindeki sürekli değişikliklere ilişkin veriler almışlar.

Hastaların yaşı, PSA düzeyi, prostat hacimleri ve idrar tahlilindeki beyaz kan hücresi sayısı, makine öğrenim algoritması için girdi verileri olarak kullanılmış. Mevcut retrospektif çalışma sonuçları, makine öğrenimi tekniklerinin prostat kanserini, PSA yoğunluğu ve PSA hızından önemli ölçüde daha iyi AUC'lerle tahmin edebileceğini gösterdiğini açıklamışlardır.

Köse (2019), Arizona civarında yaşayan, Pima Yerlilerinden 768 örnek ve 8 nitelik alınmıştır. Diyabet teşhisi için Zeki optimizasyon tabanlı Destek Vektör Makineleri (DVM) tekniği kullanılmıştır. Zeki optimizasyon-DVM yaklaşımıyla diyabet teşhisinde yüksek oranda tutarlı sonuçlar elde edilebildiğini gösterilmiş. Yapılan çalışma Yapay Zekâ tabanlı teşhis açısından önemli bir potansiyel ve başarıya sahip olduğu anlaşılmaktadır.

Wildeboer vd.(2019), prostat kanseri tanısı için multiparametrik görüntülemelerin bilgisayar destekli tanı (CAD) araçlarının geliştirilmesi konusu ele alınmıştır. Makine öğrenme yöntemlerinden derin öğrenme tekniği CAD üzerindeki değerlendirmeler ile ileri tıbbi karar verme operatörleri üzerine karşılaştırmalar yapılmıştır.

Raciti vd.(2020), prostat kanseri teşhisinde prostat iğnesi biyopsilerinin makine öğrenme algoritmaları ile dijital tahmin edilmesi üzerine çalışmışlardır. Bunun için hematoksilen ve eozin ile boyanmış prostat iğne nüve biyopsilerinin slaytların (WSI) patologların son teknoloji bir PrCa saptama sistemi olan Paige Prostat Alpha ile nasıl etkileşime girdiğini araştırmışlar. AP-board sertifikalı üç patolog ile 8 saat içinde 304 anonim prostat iğnesi biyopsisi WSI'yi değerlendirmişler. Patologlar, her bir WSI'yi iyi huylu veya kanserli olarak sınıflandırmış. Paige Prostat Alpha yeni yapay zekâ makine öğrenimi içeren sistem ile patologlar daha küçük, daha düşük dereceli tümörleri daha sık doğru bir şekilde sınıflandırmışlar ve her bir WSI'yi analiz etmek için daha az zaman harcadığı gözlediğini söylemişlerdir.

Meral vd. (2020), destek vektör makineleri regresyon yöntemini kullanmışlar ve Türkiye'deki enerji santrallerinin doğalgaz tüketimi verileri ile çalışmışlardır. Kullanılan veriler 2013-2018 yılları arasında Türkiye Enerji Piyasası Düzenleme Kurumu (EPDK) ve Enerji İşleri Genel Müdürlüğü (EİGM)' nden alınmıştır. Öngörü modelleri için Destek

Vektör Regresyonunda kullanılan tüm çekirdek fonksiyonları (Doğrusal, Polinomial, Radyal Tabanlı Fonksiyon (RTF) ve Sigmoid) kullanılmıştır. Oluşturulan model ile Mayıs-Aralık ayları için 2018 yılına ait Türkiye'deki enerji santrallerinin doğalgaz tüketimlerinin öngörüsünü yapmıştır.

Ström vd. (2020), 59159 STHLM3 katılımcısı arasında 7406'sına (%12,5) 10 veya 12 iğne çekirdeğinden oluşan standart sağlık protokolüne uygun sistematik biyopsi uygulamışlar ve 12 çekirdek 35 mL'den büyük prostat örneğini kullanmışlar. Biyopsi yapılan kişiler arasından ISUP skoruna göre sınıflandırılmış 1297 kişiyi rastgele seçimle örnekleme yapmışlar. Yapay zeka sisteminin kötü huylu ve iyi huylu çekirdekleri ayırt etme yeteneğini temsil eden AUC, bağımsız test veri seti (iyi huylu=910, kötü huylu=721) için 0.997 (%95 GA 0.994–0.999) ve 0.986 (0.972–0.996) harici doğrulama veri seti için (benign=108, malign=222) şekilde sınıflara ayrılmıştır.

Borrelli vd.(2020), prostat kanseri metastaz sürecindeki PET/BT görüntülerinden lenf nodu lezyonlarını saptamak, yorumlamalar arası değişkenlik gösterdiğini belirtmişler. Nesnel bir görüntü analizi için AL tabanlı bir araç geliştirilmiş ve doğrulama yapılmıştır. Tedaviden önceki evre 18F-kolin PET/BT uygulanan biyopsiyle kanıtlanmış PCa'lı 399 hastadan oluşan bir grup, AI tabanlı aracı eğitmek (n = 319) ve test etmek (n = 80) için kullanılmış. Derin öğrenme yöntemine dayalı erişimli sinir ağı kullanılmış. Çalışma sonunda Prostat kanseri hastalarında deneyimli okuyucular ve prognostik bilgilerle karşılaştırılabilir lenf nodu lezyonlarının değerlendirilmesini sağlayabilen PET/BT görüntülerinin otomatik ve objektif yorumlanması için yapay zekâ tabanlı bir araç kullanmanın fizibilitesi ortaya konulmuştur.

Abbasi vd.(2020), çalışmalarında prostat kanseri tespiti için radyolojik görüntüler(MRI veri tabanı, Google Net) transfer öğrenme yaklaşımı kullanmışlar derin öğrenme evrişimli sinir ağı (CNN) kullanılmışlar. Çeşitli makine öğrenme teknikleriyle (Karar Ağacı, SVM farklı çekirdekler, Bayes) ile karşılaştırılmış. Karşılaştırma sonucunda Karar Ağacı, Destek Vektör Makinesi RBF çekirdeği ve Bayes gibi çeşitli Makine Öğrenimi Sınıflandırıcıları ile oldukça iyi sonuçlar elde edilmiş fakat derin öğrenme tekniği en iyi sonucu verdiği gözlenmiştir.

Shah vd. (2020), çalışmalarında yapay zeka uygulamaları prostat kanserinin teşhisi bakımı gözlemciler arasındaki otomasyon, büyük hacimli veri kümelerinin analizini hızlı ve doğru bir şekilde sunma yetenekleri üzerinde durulmuştur. Yapay zekâ algoritmalarının sürekli eğitimi ve test edilmesi, teşhis, gelişmiş eğitim ve cerrahi sonuçlar ile prostat kanseri tahmin araçlarının geliştirilmesinde bütünleyici rollere sahip olacak fütüristik AI modellerinin geliştirilmesi yönünde bilgiler vermişlerdir.

Şensu vd. (2020) dijital patoloji temelli yapay zekâ etkinliği üzerindeki bilgiler konusuna yer vermişlerdir. Yapay zekâ çalışmalarının patoloji alanında da çeşitli kolaylıklar sağlayacağını belirtmişlerdir. Yaptıkları çalışmada, dijital patoloji ve patolojide yapay zekâ konusuna ilişkin temel terim ve tanımlamalara yer vermişler ve dijital patoloji laboratuvarı kurulurken göz önüne alınacak unsurlara yer vermişlerdir. Dijital patoloji ve patolojide yapay zekâ uygulamalarının gelecekteki avantaj ve dezavantajlarından bahsedilerek literatür taramalarına değinilmiştir.

Nelson vd. (2020), bilgisayar Destekli Tanı CAD yardımıyla MRG prostat muayenesindeki araştırmaları analiz etme üzerine çalışma yürütmüşlerdir. Çalışmalarında güncel bilimsel makalelerin sistematik bir literatür taraması yapmışlardır. Makalelerin seçimi “Sistematik İncelemeler ve Meta-Analiz için Tercih Edilen Raporlama Öğeleri” (PRISMA) kullanılarak yapılmış. Özetler, gözden geçirilen makalelerden oluşturuldu ve ardından sonuçlar için ilgili verilere kategorize edilmiş. CAD’in, duyarlılık veya özgüllük ile ilgili kapasitesinin bir radyologdan daha yüksek olduğu ilgili makalelerde gösterilmiştir.

Ström vd. (2020), çalışmalarında prostat kanseri tespiti, lokalizasyonu ve Gleason derecelendirmesi için klinik olarak kabul edilebilir doğrulukta yapay zeka (AI) sistemi geliştirmişlerdir. 28 Mayıs 2012 ve 30 Aralık 2014 tarihleri arasında yürütülen İsveç prospektif ve popülasyona dayalı STHLM3 tanı çalışmasında 11 (ISRCTN84445406) 50-69 yaşları arasında rastgele seçilmiş 976 katılımcıdan 6.682 iğne biyopsisi üzerinde çalışılmışlardır. 12 görüntü, prostat biyopsilerini değerlendirmek için derin sinir ağları kullanılmış. 13 ağ, 245 erkekten 1.631 biyopsi ve ayrıca 73 erkekten 330 biyopsiden oluşan bir tahmin seti içeren bağımsız bir test seti için 14 malign dokunun varlığı, yaygınlığı ve Gleason derecesi tahmin edilmiş. İyi huylu biyopsileri ayıklayarak ve pozitif

biyopsi çekirdeklerinde kanser uzunluğunu ölçme görevini otomatikleştirerek patoloji iş yükünü azaltacağı belirtilmiş. Patoloji uzmanlarının olmadığı yerde destek üretilen sistemin hastalık teşhisinde destek sağlayacağı yönünde bilgi verilmiştir.

Başer vd.(2020), diyabet hastalığının teşhisi için makine öğrenmesi algoritmaları destekli çalışma yürütmüşlerdir. 1999-2008 yılları döneminde ABD’de faaliyet göseleren 130 hastanedeki 70000 kayda ait vakalardan elde edilmiş veri seti üzerinde makine öğrenme algoritmalarından; Karar ağaçları, k-en yakın komşuluk, Lojistik regresyon, Naive Bayes ve Rastgele orman algoritmaları kullanmışlardır. Makine öğrenme sınıflandırma tekniklerinin karşılaştırılması sonucunda en iyi doğru sınıflandırma performansı Rastgele orman algoritması olarak ortaya çıkmıştır.

Perincheri vd.(2020), makine öğrenimi algoritmaları, anatomik patolojide tanısal doğruluğu üzerinde çalışmışlardır. Yale Tıp’daki uygulamamızdan 1876 prostat çekirdek biyopsisi tam slayt görüntüleri verileri üzerinde makine öğrenim tabanlı sınıflandırma işlemi yapılmış. "Şüpheli" veya "Şüpheli Değil" olarak ikiye ayırarak eğitim verilerin sınıflandırması gerçekleştirilmiş ve Paige Prostate kanserli çekirdek biyopsileri belirlemede %97.7 duyarlılık ve %97.9 pozitif öngörü değeri ve %99.3 özgüllük ve %99.2 negatif öngörü elde etmişler. Cerrahi patoloji uygulamalarında prostat kor biyopsilerinin değerlendirilmesi için güçlü bir iş akışı aracı olduğunu belirtmişlerdir.

Marginean vd.(2021), çalışmalarında prostat kanseri biyopsilerinde Gleason derecelendirmesinde gelişmiş standardizasyon için bir araç olarak makine öğrenimi ve evrişimli sinir ağlarına dayalı bir yapay zeka (AI) algoritması geliştirmişlerdir. 174 hastadan toplam 698 prostat biyopsisi kesiti kullanmışlardır. Korelasyon, duyarlılık ve özgüllük parametreleri hesaplandı. Algoritma, kanser alanlarını tespit etmede yüksek doğruluk gösterdiği ortaya konulmuştur ve kanseri patolojlara benzer doğrulukla saptayan ve derecelendiren hassas bir yapay zekâ aracı geliştirilmiştir.

Bibault vd.(2021), kanser teşhisinden sonraki 10 yıl içinde prostat kanseri mortalite riskini tahmin etmek ve yorumlanabilir tahmin sağlamak için gradyan arttırıcı bir model üzerinde çalışmışlardır. PLCO Kanser Taramasından ve prostat kanseri teşhisi konan

seçilmiş hastalardan elde edilen ileriye dönük veriler kullanılmış. Doğruluk $0.98 (\pm 0.01)$ ve alıcı çalışma karakteristiğinin altındaki alan $0.80 (\pm 0.04)$ olarak bulunmuştur. Prostat kanseri tedavisinde bilinçli karar vermeyi desteklemek için kullanabildiği belirtilmiştir. Bulunan model prostat kanseri tedavisinde bilinçli karar vermeyi desteklemek için kullanılabileceği yönünde görüş bildirmişlerdir.

Kim vd.(2021), çalışmalarında prostat kanseri optimal teşhisi için lekeli prostat dokularından makine öğrenme teknikleri ve geleneksel istatistiksel yöntemler kullanmışlar. Her boyanmış kanaldan birinci dereceden istatistik (FOS) tabanlı dokusal özellikleri çıkarmak için doku özelliği mühendisliği yapılmış ve önemli özelliklere dayalı olarak iyi huylu ve kötü huylu arasında kanser sınıflandırması yapmışlardır. Çıkarılan altı öz nitelikten en iyi beş öz niteliği sağlayan önemli öz nitelikleri belirlemek için özyinelemeli öz nitelik eleme (RFE) ve tek yönlü varyans analizi (ANOVA) tekniklerini kullanmışlar. İkili sınıflandırma için kullanılan yapay zeka teknikleri (iyi huylu ve kötü huylu ve düşük dereceli ve yüksek dereceli) destek vektör makinesi (SVM), lojistik regresyon (LR), torbalama ağacı, artırma ağacı ve çift kanallı çift yönlüdür uzun kısa süreli bellek (DC-BiLSTM) ağı uygulamışlar ve karşılaştırmalar yapmışlardır. Sistematik yapay zekâ uygulaması çok iyi bir sınıflama sunduğu belirtilmiştir.

Twilt vd.(2021), prostat kanseri için lezyon tespiti için yapay zeka algoritmalarını açıklayan 2018 ve Şubat 2021 arasındaki çalışmaları içeren mevcut alana genel bir bakış sağlama üzerinde çalışmışlardır. Dahil edilen 59 çalışmayı değerlendirilmiş, çoğu araştırmanın prostat kanseri lezyon sınıflandırması (%66) ve ardından prostat kanseri lezyon tespiti (%34) görevi için yapıldığı belirtilmiştir. Bahsedilen çalışmalar %85'i bağımsız tanı doğruluğu hakkında rapor verirken, %15'i yapay zekanın tanısallık düşünme etkinliği üzerindeki etkisini gösterdiği uygulamalarının klinik faydası için sınırlı kanıt göstermiş olduğu belirtilmiştir.

Wulczyn vd.(2021), çalışmalarında yapay zeka tabanlı Gleason derecelendirmesi yoluyla prostat kanserine özgü mortaliteyi tahmin etmek bir sistem geliştirilmesine dayalı çalışma yapmışlardır ve bir Avrupa merkezinden 2807 prostatektomi vakasından oluşan bağımsız bir retrospektif kohortta hastaları risk katmanlandırma yeteneğine bakılmıştır.

Yapay zeka tabanlı Gleason derecelendirmesinin etkili risk sınıflandırması yaptığını ve tedavinin iyileştirilmesi için daha fazla değerlendirme yapılmasını garanti ettiğini göstermişlerdir.

Bulten vd.(2021), prostat biyopsilerini derecelendirmek için derin öğrenmeye dayalı yapay zeka yardımıyla değerlendirmesi üzerinde çalışmışlardır. Derin öğrenme yöntemiyle 160 biyopsi derecelendirilmiş. Yapay zekâ kullanıldığında, uzman referans standardı ile uyumu önemli ölçüde arttığını gözlemlemişler.(kuadratik ağırlıklı Cohen's kappa, 0.799'a karşı 0.872; $p = 0.019$). Yapay zeka destekli patoloğlar, yardımsız patoloğlardan ve bağımsız yapay zeka sisteminden daha iyi performans gösterdiği belirtilmiştir.

Harmon vd.(2021), prostat kanseri için immünohistokimyasal (IHC) boyalı kesitlerde PTEN kaybının otomatik tespiti ve lokalizasyonu temelli yapay zeka (AI) sistemi geliştirmişler. Her iki kohorttan, dahili (180/1239) ve harici %13,5 (43/319) kanser çekirdeklerinde PTEN kaybı sıklığı ile toplam 2700 çekirdek üzerinde çalışmışlar. TMA çekirdekleri, patoloğlar tarafından PTEN kaybı için görsel olarak puanlanarak açıklanmıştır. Çoklu çözünürlüklü ve piksel tabanlı modellerin birleştirilmesinden yapay zeka tabanlı tahmin modeli oluşturulmuş. Performans, 428 harici kohort çekirdeğinde değerlendirilmiş. Alınan sonuçlar sayesinde prostat kanseri doku örneklerinde PTEN kaybının tespiti ve lokalizasyonu için sağlam ve tam otomatik bir yöntem oluşturulmuştur.

Booven vd.(2021), Yapay zeka algoritmalarının prostat kanseri hastalarının özellik düzeyini, prostat kanseri teşhisi, yönetiminde genel verimliliği, doğruluğu üzerinde sistematik derleme çalışması yapılmış. Yapay zekâ temelli yapay sinir ağlarındaki (YSA) gelişmeleri ve bunların prostat kanseri teşhisi ve yönetimindeki rolü üzerinde durulmuştur.

Tătaru vd. (2021),” Prostat Kanseri Hasta Yönetiminde Yapay Zeka ve Makine Öğrenimi—Güncel Eğilimler ve Gelecek Perspektifler” adlı çalışmalarında yapay zekanın prostat kanseri erken tanı teknikleri biyomedikal araçlar üzerine yapılmış ve yapılması beklenen çalışmalar bahsedilmiştir. Radyoterapi, prostat kanseri tedavisinin önemli bir parçasıdır ve hastalar için toksisitesinin tahminin zor olduğu belirtilmiş. Yapay zeka,

hastalarda radyoterapi sonrası ne gibi yan etkilere maruz kalabileceđi konusunda tahmin etmede önemli bir role sahip olduđu belirtilmiştir. Yapay zekanın cerrahi robotların etkinliklerinin daha özgü görevler için genişletilmesi, cerrahi alandan gelen güncel bilgileri kullanmalarına, problemleri tanımlarına ve insan müdahalesine ihtiyaç duymadan uygun eylemleri gerçekleştirmelerine katkı sunacağı yazılmıştır.



3. METARYAL VE YÖNTEM

3.1. Yapay Sinir Ağları

Teknoloji zaman geçtikçe insan ve makine arasındaki bağıntıyı güçlendirerek ilerlemektedir. Bilim insanları, insanlar için basit ve karmaşık olan görevler için makineleri etkili bir şekilde kullanıma sunmaktadır.

İnsan beyni zamanla gelişir bu gelişmeye tecrübe veya deneyim ismi verilir. Teknik anlamda bakıldığında bu gelişimlere uyum sağlamak nöronların(insan sinir hücrelerinin) gelişmesini içerir. Nöronlar kendilerini çevreleyen ortama bu gelişimi aktarır, böylece beyni bilgi işleme yeteneği esnek bir hal alır. Örneğin insan, tecrübeler ve örnekler sayesinde ateşe dokunmamayı, bir öğretmenle birlikte hece kurmayı, bir kediye köpekten ayırt etmeyi kolayca öğrenebilmektedir. Deneyimler artıka davranışsal ve düşünsel karar verme performans süreci hassas bir şekilde daha iyi yönde devam eder. Benzer kalıplar ve verileri gruplama ihtimali yükselir. Bunun sonucunda hayattan sistemsel karar verme sürecinin kuralları tanımlanabilir, fakat bu süreç boyutu gerçeği yansıtmaz. Günlük hayattan bir örnekle devam etmek gerekirse temel gıda ve diğer harcamaları sınıflandırmaya ve gelirimiz ölçüsünde belirli kısıtlanmalar ile hedef olan yaşam standardına ulaşılabilir. Bu kısıtlar makineye hangi görev ve hedefleri tanımlanacağını ve hangi kısıtları koyup optimum sonuçlara ulaşabileceğini net bir şekilde gösterir. Elastik olma özelliği ve karar süreçleri yapay sinir ağı mimarileri için büyük önem taşımaktadır. Çünkü öğrenme sistemleri olan sinir ağı sistemleri, daha önce öğrenilen bilgileri korumalıdır, aynı zamanda yeni bilgileri öğrenmeye açık olmalıdır. Yapay sinir ağı önemli veya faydalı bilgiler için "Esnek" kalması, ancak alakasız bilgilerle sunulduğunda "kararlı" kalması gerekmektedir. Bu, kararlılık- esneklik ikilemi olarak bilinir (Carpenter ve Grossberg, 1987, 1988).

NN'ler, merkezi sinir sisteminin basitleştirilmiş taklitleridir ve bu nedenle, insan beyni tarafından gerçekleştirilen türde bir hesaplama ile tasarlanır. Geleneksel sıralı, mantık tabanlı dijital bilgi işlem birçok alanda üstündür, fakat diğer problem türleri için

daha az başarılı olduğu görülmüştür. Geleneksel hesaplamanın doğası gereği sıralı işlemlerde karşılaşılan sınırlamalar, sinir ağı araştırmaları için bazı yeni yönleri oluşturmuştur. Yapay sinir ağlarının gelişimi, beyni anlamaya ve beynin bazı güçlü yönlerini taklit etmeye çalışmıştır.(Fausett,1994) Yapay Sinir ağları insan beyninin en temel özelliği olan öğrenme fonksiyonunu gerçekleştiren bilgisayar sistemleri haline gelmiştir.

3.1.1. Yapay sinir ağları kullanım alanları

Sinir ağları, farklı nedenlerle birçok alanda araştırmacıların ilgisini çekmektedir. Bunlar aşağıda verilmiştir.

- Elektrik mühendisleri, sinyal işleme ve kontrol teorisinde kullanım sağlamaktadır.
- Bilgisayar mühendisleri, donanımın sinir ağlarını uygulama potansiyeli yüksek olması ve sinir ağlarının robotik uygulamalarının olması sebebiyle ilgilerini çekmektedir.
- Bilgisayar bilimcileri ve veri bilimciler, sinir ağlarının yapay zekâ ve örüntü tanıma gibi alanlarda zor problemler için yeni mimariler yeni uygulamalar üretebilmektedir.
- Uygulamalı matematikçiler için sinir ağları, belirli değişkenler arasındaki ilişkilerin açık biçiminin bilinmediği problemleri modellemek için güçlü araç haline gelmiştir.
- Sağlık bilimcileri ve multidisiplinler arası çalışan araştırmacılar için hastalıkların teşhisinde sinir ağlarının kullanılması önemli hale gelmiştir.(Fausett,1994)

3.1.2. Yapay sinir ağlarının biyolojik ve matematiksel formu

Bir yapay sinir ağı, biyolojik sinir ağ yapısı ile aynı performans özelliklerine sahip bilgi işlem merkezidir. Biyolojik sinir sistemi milyarlarca sinir hücresinden oluşmaktadır. İnsan beyninin yapısal sinir formu incelendiğinde 10^{10} adet sinir hücresinin ve hücreler arası haberleşme gibi birden fazla özellik taşıyan $6 \cdot 10^{13}$ adet bağlantı mevcuttur.

3.1.3. İnsan beyni ile sinir ağlarının benzer temel yapıları

İnsan beyni gerek fizyolojik gerekse biyolojik yapısı yüzyıllardır çözüme ulaşılmaya bekleyen karmaşık ve hayran uyandırıcı bir yapıdır. Beyin insan vücudunda birçok organın yönetilmesi hayati görevlerin yerine getirilmesinde büyük rol oynar. İnsanlar beynin rollerini makineye aktarmak ve bu makine ile optimal kararlar, stratejiler, hesaplamalar yapabilmek için benzer matematiksel modeller ve yapılar üretmeye çalışmaktadır. En önemli ve insan beynine benzer yapılar bilgisayarın donanım ve yazılımları ile görülmektedir. Örneğin;

Ram (Random Access Memory): Geçici/uçucu hafıza olarak tanımlanır. İnsan beyni 7 artı eksi 2 parçayı/bit geçici hafızadaki zihinde tutabilir. Bilgisayardan farkı ise geçici hafızanın beynin aslında her bölgesinden gerçekleşmesidir.

Hard Disk: Öğrenme yeteneğinin gerçekleştiği bölgedir. Beyinde sinaptik bağlantılar oluştuğunda öğrenme kalıcı olur ve fiziksel değişiklikler yaratabilir. Hard disk beyinde uzun dönemli hafızaya denk gelmektedir.

CPU (Central Processing Unit): Bilgisayarların ana işlemcisidir. İnsan beyninin kendisi hem işlemci hem de yazılım kısmını bir bütün halinde sunmaktadır. Beynin işlemci gibi bir ünitesi mevcut değildir.


GPU (Graphical Processing Unit): Bilgisayarlarda grafik kartı olarak tanımlanır. İnsanın gözleri ile beyni arasındaki bağıntı bu grafik kartına örnek olur.

Çevresel Üniteler: Bilgisayardaki kamera, klavye gibi üniteler beyine 5 duyu organı ile iletilir ve işlenir.

ROM (Read-only Memory): Üzerine yazılamayan sadece okunabilen hafızaya ROM ismi verilir. İnsan beyninde ROM'a karşılık gelen, ünite omurilik veya alt beyindir. Değiştirilemez bir kod içerir ve insanların nefes almasını, terlemesini, yürümesini sağlar.

BIOS (Basic Input/Output System): Beynin en derininde bulunan bilgisayarın temel giriş çıkış sistemi BIOS'dur. Refleks gibi çok temel kodların olduğu bir ünite olarak tanımlanabilir.

Beynin fizyolojik yapısı basit bir çizimle Şekil 3.1 'de gösterilmektedir.




Şekil 3.1. İnsan beyninin fizyolojik yapısı

3.1.4. Sinir hücreleri

1911'de Ramón Y. Cajál'a tarafından beynin temel bileşeni olarak nöronlar kavramı ortaya atmasıyla beyni anlamamıza ve beynin işleyişinin incelenmesi nispeten daha kolay hale gelmiştir.

Beyin, nöron adı verilen yaklaşık 1010 temel birim içerir. Her nöron sırayla yaklaşık 104 diğer nörona bağlıdır. Bir nöron, çeşitli kaynaklarından elektro-kimyasal sinyaller alan ve sırayla diğer nöronlara elektriksel uyarılar ileterek yanıt veren küçük bir hücredir. Ortalama bir beyin yaklaşık 1,5 kg ağırlığında ve ortalama bir nöronun ağırlığı $1,5 \times 10^{-9}$ gramdır. Nöronlardan bazıları giriş ve çıkış işlemlerini gerçekleştirirken geri kalanlar sinyal dönüşümünden ve bilginin depolanmasından sorumlu olan birbirine bağlı bir nöron ağının bir parçasını oluşturur. Ancak, farklı aktivitelerine rağmen, tüm nöronlar ortak özellikleri paylaşır.

Bir biyolojik sinir hücresi yapısı Şekil 3.2’ de verilmiştir.



Şekil 3.2. Biyolojik sinir hücresi


Şekil 3.2’deki gibi bir biyolojik sinir ağı hücresi olarak adlandırılan nöron aksonlar, sinapslar, hücre gövdesi, dendritler gibi elamanlardan oluşmaktadır. Soma hücre gövdesi olarak adlandırılır. Somaya bağlı, dendrit adı verilen uzun düzensiz şekilli filamentlerdir. Dendritler giriş kanalları gibi davranırlar, (yani) diğer nöronlardan gelen tüm girdiler dendritler yoluyla ulaşır. Dendritler yapraklarını dökmüş ağaç dallarına benzer. Somaya bağlı başka bir bağlantı türü de Akson'dur.

Dendritik bağlantılardan farklı olarak, akson elektriksel olarak aktiftir ve bir çıkış kanalı olarak hizmet eder. Esas olarak çıkış hücrelerinde görünen aksonlar, yaklaşık bir milisaniye süren Aksiyon Potansiyeli veya Spike adı verilen bir voltaj darbesi üreten doğrusal olmayan eşik cihazlarıdır. Soma tarafından alınan kümülatif girdiler,” Zar Potansiyeli” olarak bilinen hücrenin iç elektrik potansiyelini yükseltirse, o zaman nöron, diğer nöronları uyarmak veya inhibe etmek için aksiyon potansiyelini akson boyunca yayarak ateşlenir.

Akson, aksonu başka bir nöronun dendritik bağlantılarına bağlayan sinaps veya sinaptik bağlantı adı verilen bir bağlantı ile son bulur. Dendritik bağlantının sonunda çok küçük bir boşluk olan sinaptik bağlantı, bir nöro-iletici sıvı içerir. Somaya giden elektrik yüklerini hızlandırmaktan veya geciktirmekten sorumlu olan bu sıvıdır. Her dendritik bağlantı, üzerinde hareket eden birçok sinapsa sahip olabilir ve bu karşılıklı bağlantının

nedenini açıklamaktadır. Genel olarak, tek bir nöron birçok sinaptik girdiye ve sinaptik çıktıya sahip olabilir. Fakat sinapsların boyutu öğrenmeyle ilişkilendirilebilmektedir.

İnsan beyni, nöron adı verilen basit işlem öğelerinden oluşan devasa büyüklükte bağlantılı bir ağ olarak görülen son derece karmaşık bir yapıdır. Bununla birlikte, bir nöronun davranışı, Şekil 3.3 de gösterildiği gibi basit bir model ile tasarlanabilir. Modelin her bileşeni, biyolojik bir nöronun gerçek bileşenlerine bir benzetmedir bu sebeple yapay nöron olarak isimlendirilir. Yapay Sinir Ağlarının temelini oluşturanda bu modeldir.



Şekil 3.3. Yapay sinir ağı hücresi

Şekil 3.3 gibi bir yapay sinir hücresi giriş, ağırlık, eşik, toplama fonksiyonu, aktivasyon fonksiyonu, çıkıştan oluşmaktadır. Burada $x_1, x_2, x_3, \dots, x_n$ yapay nöronun n girdisidir. $w_1, w_2, \dots, w_n$ giriş bağlantılarına eklenen ağırlıklardır.

Yapay sinir ağı, aşağıdaki varsayımlarla biyolojik sinir ağının matematiksel olarak modellenmesiyle oluşturulmuştur. Bunlar;

1. Bilgi işleme, nöron adı verilen sinir hücresinde gerçekleşir.
2. Sinyaller, nöron ve bağlantılar (aksonlar) boyunca iletilir.
3. Her bağlantı biyolojik sinir hücresindeki nörontrasmitler maddeler gibi belli bir ağırlığa sahiptir.
4. Her nöron, çıkış sinyalini belirlemek için net girişine (ağırlıklı giriş sinyallerinin toplamı) bir aktivasyon fonksiyonu ile gerçekleşir.

3.1.5. Yapay sinir hücrelerini (nöron) oluşturan elamanlar

Bir sinir ağı, nöronlar, birimler, hücreler veya düğümler olarak adlandırılan çok sayıda işlem katmanlarından oluşur. Her nöron, belirli ağırlığa sahip, yönlendirilmiş iletişim bağlantıları yoluyla diğer nöronlara bağlanır.

i. Girdi

Girdi katmanını dışardan gelen bilgileri toplar. Dış dünyadan gelen bilgiler kadar ise sinir hücresi bulunmaktadır. Bu katmandan gelen bilgiler hiçbir işleme alınmadan diğer katmana iletilir.

ii. Ağırlıklar

Girdi katmanına gelen bilgilerin iletilmesi sürecinde hücre içinde bu bilgilerin önemini ve etkisini belirlemektedir. Bu etkiler pozitif veya negatif olabilir.

iii. Toplama fonksiyonu

Ağırlıklar ile girdilerin çarpılması ile Net girdi değeri oluşur. Net girdi ya da toplama fonksiyonu ağı gelen değer olarak açıklanır. Net girdinin genel kullanım fonksiyonu aşağıda verilmiştir.

$$\text{NetGirdi} = \sum_{i=1}^n X_i \cdot W_i \quad (3.1)$$

$i = 1, 2, 3, \dots, n$

x : Her bir girdi

W : 1, 2, 3, ..., n kadar girdiye verilen rastgele ağırlık parametresi

Yapay sinir ağının toplama fonksiyon çeşitleri

4.1.'de verilmiştir.

NetGirdi	Fonksiyon Açıklaması
$\text{NetGirdi} = \text{Max}(X_i, W_i)$	$i=1,2,3,\dots,n$ girdilerden her biri rastgele verilmiş ağırlık değerleriyle çarpılır ve elde edilen değerlerden en büyüğü net girdi olarak belirlenir
$\text{NetGirdi} = \text{Min}(X_i, W_i)$	$i=1,2,3,\dots,n$ girdilerden her biri rastgele verilmiş ağırlık değerleriyle çarpılır ve elde edilen değerlerden en küçüğü net girdi olarak belirlenir.
$\text{NetGirdi} = \sum \text{sgn}(X_i, W_i)$	$i=1,2,3,\dots,n$ girdilerden her biri rastgele verilmiş ağırlık değerleriyle çarpılır ve elde edilen değerlerden pozitif ve negatif değerler elde edilir. Pozitif ve negatif değer sayısı belirlenir. Büyük olan sayı net girdi olarak belirlenir.
$\text{NetGirdi} = \text{NetGirdi} + \sum (X_i, W_i)$	Sinir hücresine gelen bilgiler ağırlıklar ile çarpılarak toplanır ve daha önce gelen bilgilerle toplanır.

Çizelge 3.1. YSA toplama fonksiyonları

iv. Aktivasyon fonksiyonu ve çeşitleri

Toplama fonksiyonunda çıkan veriler karmaşık ve çok büyük olabilir. Toplama fonksiyonundan elde edilen NetGirdi değerleri ile aktivasyon fonksiyonuna geçilir. Aktivasyon fonksiyonu olmayan bir yapay sinir hücresi , verilerdeki karmaşık yapıları öğrenip tespit etmesi oldukça zor ve yetersizdir. Aktivasyon fonksiyonu içermeyen bir yapay sinir ağı temel lineer regresyon modelinden farksızdır. Bu fonksiyon NetGirdi değerini işler ve mevcut ağın üreteceği çıktıyı belirler. Genel kabul görmüş bir aktivasyon fonksiyonu bulunmamaktadır. Veriler için iyi bir aktivasyon fonksiyonu özellikleri aşağıda verilmiştir.

- **Doğrusal olmamalı:** Karmaşık verilerin problemlerin çözümünde aktif rol oynaması sebebiyle doğrusal yapıya sahip olmamalıdır.
- **Türevlenebilir olmalı:** Sinir hücresinde minimum kayıp değerini veren parametreler, geri yayılım algoritması (**Back Propagation**) ile belirlenir. Back propagation sayesinde türevleyebiliriz. Türevlenmez ise en iyi parametre seçimi yapılamaz.
- **Alt ve üst sınıra sahip olmalı:** Sınırları belirlenmemiş bir aktivasyon fonksiyonunda çıktı sorunları ortaya çıkabilir.
- **Monoton artan veya azalan olmalı:** Aktivasyon fonksiyonun monoton artan veya azalan olması durumunda minimum ve maksimum noktaları bulunur.
- **Orijin noktasında kendine yakınsamalı:** Bir aktivasyon fonksiyonunun orijin noktasında kendine yakınsaması, rastgele ağırlık değerleriyle birleştirilmiş NetGirdi değerlerinin eğitimi kolaylaştırır.(Rajesakaran,2012)

Aktivasyon fonksiyonu çeşitlerinden bazıları şunlardır;

a) Sigmoid fonksiyon fonksiyonu


Sigmoid fonksiyonunun adı fonksiyonun kartezyen uzayda çizilmiş halinin andırdığı S harfinden (sigma) gelmektedir. 0 ve 1 arasındaki $F(\text{NetGirdi})$ değerleri için tanımlı olup $\text{NetGirdi} = 0$ ekseninden önce 0'a sonrasında ise 1'e yakınsamaktadır.

Sigmoid fonksiyonunda hem lineer hem de lineer olmayan fonksiyonların her ikisi içinde çıktılar oluşturularak modelleme yapılır (Öztemel,2012). Sigmoid fonksiyonu ağırlıklı ortalamayı 0-1 arasında bir değere yakınsar.

Sigmoid fonksiyonu için NetGirdi değeri aşağıda denklem (3.2) de verilmiştir.

$$F(\text{NetGirdi}) = \frac{1}{1 + e^{-\text{NetGirdi}}} \quad (3.2)$$

Sigmoid fonksiyonu için grafik Şekil 3.4 de verilmiştir.



Şekil 3.4. Sigmoid fonksiyonu

n:NetGirdi

Algoritma: $\text{Logsig}(n) = 1 / (1 + \exp(-n))$


b) Hiperbolik Tanjant fonksiyonu

Hiperbolik fonksiyonlar sıradan trigonometrik fonksiyonların matematiksel modellenmesidir. Yapay sinir ağlarında en çok kullanılan aktivasyon fonksiyonlarından biridir. Hiperbolik fonksiyonu kullanabilmek için girdi değerleri (X_i)'ler (-1,1) aralığında standartlaştırılır. (Vogl vd.1988).

Hiperbolik Tanjant ile ağırlık değeri denklem(3.3) 'de ki gibi hesaplanır;

$$F(\text{NetGirdi}) = \frac{e^{\text{NetGirdi}} - e^{-\text{NetGirdi}}}{e^{\text{NetGirdi}} + e^{-\text{NetGirdi}}} \quad (3.3)$$

Hiperbolik Tanjant fonksiyonu için grafik Şekil 3.5 de verilmiştir.



Şekil 3.5. Tansig fonksiyonu

n:NetGirdi


Algoritma: $\text{Tansig}(n) = 2 / (1 + \exp(-2 \times n)) - 1$

c) Doğrusal fonksiyon

Yapay sinir ağlarında kullanılan bir başka aktivasyon fonksiyonu ise doğrusal fonksiyondur. Bu fonksiyonun kullanılması durumunda NetGirdi değeri çıktı değeri olarak yansıtılır. Veri yapısı veya modelin doğrusal olması durumunda pürelin fonksiyon tercih edilir (Demuthve Beale,2000).

$$F(\text{NetGirdi}) = \text{NetGirdi} \quad (3.4)$$

Doğrusal (Purelin) fonksiyonu için grafik Şekil 3.6'da verilmiştir.




Şekil 3.6. Doğrusal aktivasyon fonksiyonu

d) Doğrusal pozitif fonksiyon

Pozitif doğrusal bir fonksiyondur. Poslin fonksiyonunda ağın NetGirdi 0'dan büyükse veya eşit ise NetGirdi değerini 0'dan küçük ise negatif değer alamadan 0 değerini alır.

Doğrusal Pozitif (Poslin) fonksiyonu için grafik Şekil 3.7. de verilmiştir.



Şekil 3.7. Poslin fonksiyonu

Algoritma: NetGirdi, Eğer $NetGirdi \geq 0$

0 ,Eğer $NetGirdi < 0$

e) Step fonksiyon


Eşik değerinden (T) küçük veya eşit tüm NetGirdi ağ çıktı olarak 0 verirken, eşik değeri büyük değerlerde ağ 1 değerini sunar.

Algoritma: 1, *Eğer NetGirdi > T*
0, *Eğer NetGirdi ≤ T*

f) Rampa fonksiyonu

Algoritma: $\text{Rampa}(\text{NetGirdi}) = \begin{cases} 0, & \text{Net} < T_1 \\ \frac{\text{NetGirdi} - T_1}{T_2 - T_1}, & T_1 \leq \text{NetGirdi} \leq T_2 \\ 1, & \text{NetGirdi} > T_2 \end{cases}$

Step fonksiyonu için grafik Şekil 3.8. de verilmiştir.



Şekil 3.8. Rampa fonksiyonu

g) Gauss fonksiyon

Gaussian Fonksiyonu simetrik bir fonksiyondur. Girdi eşit negatif ve pozitif değerleri ile çıktı sonucunda görülür. Çıktıların mesafesi 0'dan uzaklaşırsa maksimum çıktı

verilir.Fonksiyon deęeri aktivasyon deęerinin artan mutlak deęeri ile azalır(Debes vd.,2005)

n: NetGirdi Deęeri $\sigma = Varyans$

Algoritma: $Gaussian(n) = e^{-\frac{n^2}{2\sigma^2}}$

h) Satlin ve Satlins fonksiyonları

Algoritma: satlin(NetGirdi)= 0, Eęer NetGirdi ≤ 0
NetGirdi, Eęer $0 \leq \text{NetGirdi} \leq 1$
1, Eęer NetGirdi ≥ 1

Algoritma: satlins(NetGirdi)= -1, Eęer NetGirdi ≤ -1
NetGirdi, Eęer $-1 \leq \text{NetGirdi} \leq 1$
1, Eęer NetGirdi ≥ 1

g) Hardlim ve Hardlims Fonksiyonları

Algoritma: Hardlim(NetGirdi)= 1, Eęer NetGirdi ≥ 0
0, Aksi Takdirde

Algoritma: Hardlims(NetGirdi)= 1, Eęer NetGirdi ≥ 0
-1, Aksi Takdirde


Bunlar dıřında aktivasyon fonksiyonları Radbas, Softmax, Tribas gibi fonksiyonlarda mevcuttur.

3.1.6. İlk yapay sinir ağ modelleri

İlk yapay sinir ağları modellerine ilişkin bilgiler izleyen alt kesimlerde verilmiştir.

3.1.6.1. Tek katmanlı algılayıcılar (TKA)

Tek katmanlı algılayıcılar giriş, toplama/aktivasyon görevi yapan bir gövde ve çıkış katmanından oluşur. Her ağın birden fazla girdisi ve çıktısı mevcuttur. Çıktı katmanı girdi katmanına bağlanmakta ve her bağlantının bir ağırlığı(W) mevcuttur. Tek katmanlı algılayıcı sinir ağına örnek şekildeki gibidir. Şekil 3.9’da iki girdi elamanı bir çıktı elamanı ve ağın çıktı değerinin sıfır olmasını engelleyen eşik değer (θ) mevcuttur. Eşik değeri ise her zaman 1’dir. Tek katmanlı algılayıcı modeli Şekil 3.9 ‘da verilmiştir.



Şekil 3.9. Tek katmanlı algılayıcı modeli (Öztemel, 2006)

Ağın çıktı değeri fonksiyonel hesaplaması Denklem 3.5. deki gibidir.

$$\zeta = f\left(\sum_{i=1}^n W_i X_i + \theta\right) \quad (3.5)$$

Denklem.. de görüldüğü gibi ağın çıktı değeri ağırlıklandırılmış girdi değerlerinin eşik değerle toplanması sonucunda oluşur. Girdi değerleri bir aktivasyon fonksiyonu uygulanarak ağın çıktısı bulunur.

Tek katmanlı algılayıcılarda çıktı fonksiyonun doğrusallığı ağa sunulan örnekleri iki sınıfa ayıran doğrunun bulunması olarak açıklanır. Doğrusallığı sağlamak için eşik değeri kullanır. Ağın çıktısı burada 1 veya -1 değerini alır. 1 veya -1 değerini alması hangi sınıfta olduğunu temsil etmektedir.


$$f(x) = \begin{cases} 1, & \text{Eğer } \zeta > 0 \text{ ise} \\ -1, & \text{dd.} \end{cases} \quad (3.6)$$

Denklem 3.6 incelendiğinde ağa gelen toplam girdi pozitif ise 1 negatif ise -1 dir. Foksiyon yapısı iki sınıfa ayıran bir doğru olduğu ve doğrusallığın varlığını göstermektedir.

3.1.6.2. Basit algılayıcı modeli (Perseptron)

Basit algılayıcılar modeli Rosenblatt 1958 yılında ortaya atılmıştır. Temelde, basit algılayıcılar örüntü (şekil) sınıflandırma amacıyla kullanılmıştır. Bir arada bulunan sinir hücrelerinin sayısına bağlı olarak, basit algılayıcılar ile farklı sayıda sınıflandırma problemi çözebilir. Doğruluğu yüksek bir sınıflandırma için sınıfların düzlemsel olarak ayrılması gerekliliği sunulmuştur. (Nygren, 2004, Minsky ve Papert, 1969).

Basit algılayıcılar bir yapay sinir hücresinin birden fazla girdiyi alarak bir çıktı üretmesi kurallarına dayanmaktadır. Ağın çıktısı bir veya sıfırdan oluşan mantıksal değerdir. Ağın yapısı Şekil 3.10. da gösterilmektedir.



Şekil 3.10. Basit algılayıcı yapısı (Elmas, 2003)

Şekil 3.10’da görüldüğü gibi perseptron ile eğitilebilen tek bir yapay sinir hücresinden oluşur. Ağırlıklar değiştirilerek ağ eğitilebilir bir duruma getirilir. Girdiler proses elamanına sunulur ve her bir girdi setine karşılık çıktı değerleri ağa gösterilir. Sonuç olarak öğrenme kuralına göre ağın çıktı değeri hesaplanır. Ağın çıkışı istenilen çıktıdan farklı bir değer gelmesi durumunda eşik değerler değiştirilebilir. İlgili değişikliğin nasıl gerçekleşmesi gerektiğini öğrenme kuralına bağlı olarak gerçekleşir.

- Basit algılayıcı öğrenme kuralı

Basit algılayıcının matematiksel yapısı ve öğrenme kuralı aşağıda açıklanmıştır.

i. Ağ yapısına girdi elamanlarının seti(X) ve hedeflenen çıktı(Y) gösterilir.

$$X=(X_1, X_2, X_3, X_4 \dots X_n)$$

$$Y=(1,0)$$

ii. Perseptron katmanına gelen net girdi Denklem 3.6 gibi hesaplanır.

$$NetGirdi = \sum_{i=1}^n X_i W_i \quad (3.6)$$

iii. Perseptron katmanının çıktısı hesaplanır. NetGirdi değerinin eşik değerinden büyük veya küçük olması durumuna göre Perseptron katmanının çıktı değeri 0 veya 1 olarak bulunmaktadır.

Çıktı değeri aşağıdaki Denklem 3.7. de ki gibidir.

$$f(x) = \begin{cases} 1, & \text{NetGirdi} > \theta \\ 0, & \text{NetGirdi} \leq \theta \end{cases} \quad (3.7)$$

3.1.7. Çok katmanlı algılayıcı

Tek katmanlı algılayıcılar doğrusal problemin çözümünde kullanılmaktadır. Ancak gerçek hayattaki problemlerin birçoğu böyle bir doğrusallık göstermeyebilir. Doğrusallık varsayımının gerçekleşmediği durumlarda tek katmanlı yapay sinir ağları problemler için sonuç üretmez bu sebeple 1969 yılında tek katmanlı yapay sinir ağları mimarisinin zayıf olduğu anlaşılmıştır. Bu gelişmeyle yapay sinir ağlarına olan ilgiler azalmıştır ve neredeyse durmuştur. Durgunluk hali çok katmanlı algılayıcıların oluşturulmasına kadar devam etmiştir.

Ağın yapısının oluşturulmasında süreç elamanlarının sayısının belirlenmesi çok önemlidir. Kesin sayıları belli olmadığından deneme yanılma yoluyla ya da tecrübelerle dayanarak belirleme işlemi yapılabilir. Bu aşamasının atlatılabilmesi için ya çok fazla sayıda süreç elamanı katmanlara yerleştirilip kademeli azaltma ile hatanın düşürülmesine çalışılır ya da katmanlardaki süreç elamanı sayısı çok az tutulur. Kademeli olarak artırılarak hatanın azaltılmasına çalışılır. Çok katmanlı ağların gerçek hayattaki doğrusal olmayan problemlere uygun olması bunların daha çok tercih edilen olmasını sağlamıştır. Tek katmanlı algılayıcılara göre en büyük sorunu işlemlerinin çok uzun sürelerle alabilmesidir.


3.1.7.1. Çok katmanlı ağların mimari yapısı

Çok katmanlı ileri beslemeli ağlarda nöronlar arasındaki bilgi girişten çıkışa doğru tek yönlü düzenli katmanlar halindedir.(Uğur ve Kınacı, 2006)

Bir katmanda sadece kendinden sonra gelen katmana bağlanmıştır. Ve bir nöronun çıktısı sadece kendinden sonra gelen nöron katmanına girdi olabilir. Aynı katmandaki başka bir nörona bağlantı yoktur.(Haykin, 1999)

Bu ağlara örnek olarak çok katmanlı algılayıcılar (MLP) ve sayılaştırılmış öğrenme vektörü(LVQ) verilebilir(Saygılı, 2008).

İleri beslemeli ağlar sinir hücreleri girdi katmanı gizli katman ve çıktı katmanı olarak adlandırılan katmanlarda işlem görülür. Öğrenilmesi gereken bilgi girdi katmanından çıktı katmanına doğru hareket eder. Ayrıca bu üç katmanın birbiri ile alakası yoktur. Şekil 3.13. de çok katmanlı ağ mimarisi gösterilmiştir.




Şekil 3.11. Çok katmanlı ağ mimarisi

Network (ağ), verilen girdi için hedef çıktı bulmaya çalışmaktadır. Ağın yapısı ise, Şekil 3.11 de görüldüğü üzere, üç farklı katmandan oluşur. Gelen bilgilerin ara katmana iletilmesini sağlayan katman girdi katmanı olarak adlandırılır. Bir veya birden çok sayıda ara katman söz konusu olabilir. Ara katmanlarda, girdi katmanından alınan bilgiler işlenmektedir. Çıktı katmanında ise ara katmandan alınan bilgilere karşılık olan her bir girdi için çıktı değerleri saptanmaktadır. Katmanlar arasında süreç elemanları birbiriyle bağlantılıdır.

3.1.7.2. Çok katmanlı ağın modeli

Çok katmanlı ağ öğretmenli öğrenme stratejisini kullanır. Ağa hem örnekler hem de örneklerden elde edilmesi gereken çıktılar verilmektedir. Sistem, kendisine gösterilen örneklerden genellemeler yaparak problem uzayını temsil eden bir çözüm uzayı üretmektedir. Daha sonra gösterilen benzer örnekler için bu çözüm uzayı sonuçlar ve çözümler üretebilmektedir. Çok katmanlı ağ hücresinin matematiksel gösterimi Şekil3.14 gösterilmektedir.



Şekil 3.12. Çok katmanlı ağ hücresi

n: net giriş toplamı


a: çıkış

f: aktivasyon fonksiyonu ;

- Sigmoid
- Tanh
- Lineer.

Birden fazla giriş verisi için bir nöronun kullanılması genelde yeterli olamamaktadır. Paralel işlemler yapabilen birden çok nörona ihtiyaç duyulduğunda katman kavramı oluşturmaktadır. S tane nöronun tek bir katmanı şekilde gösterilmiştir. Burada bulunan her bir giriş hücresi bir nöronla ilintilidir.

Çok katmanlı ağ yapısının fonksiyonel yapısı Şekil 3.13’de verilmiştir.



Şekil 3.13. Çok katmanlı ağ hücresi ağırlıklar fonksiyonel yapısı

3.1.7.3. Çok katmanlı ağın öğrenme kuralı


ÇKA(çok katmanlı algılayıcı) modelinde ağın çıktısının hesaplandığı İleri Doğru Hesaplama ve ağırlıkların güncellemesinin yer aldığı Geriye doğru hesaplama olmak üzere iki aşama vardır.

İleri doğru hesaplama aşamasında girdi katmanında yer alan k adet süreç elemanının olduğunu düşünölsün. Buna bağılı olarak girdi katmanındaki süreç elemanlarının çıktısı:

$$C_{ik} = G_k$$

olarak ifade edilmektedir.

Girdi elemanlarının proses elamanı çıktığı Şekil 3.16 gösterilmiştir.



Şekil 3.14. Girdi katmanının proses elemanı çıktısı

Ara katmanda süreç elemanları için NET girdi değerleri hesaplanırken, A_{kj} k. girdi elemanının j. ara katman elemanına bağlandığı ağırlık değeri olmak üzere, eşitlik (3.1) aracılığı ile hesaplanmaktadır.

$$NET_{ja} = A_{kj} \cdot \check{C}_{ki} \quad (3.1)$$

Ara katmanda yer alan NET girdi değerleri ve aktivasyon fonksiyonu yardımıyla j. ara katman elemanının çıktı değeri hesaplanır. Sigmoid fonksiyonu aktivasyon fonksiyonu olarak yaygın şekilde kullanılmaktadır. Sigmoid fonksiyonu tercih edildiğinde ara katmanda yer alan j. elemanın çıktı değeri Eşitlik (3.2) ile verilmiştir.

$$\check{C}_{ja} = \frac{1}{1 + e^{-(NET_{ja} + B_{ja})}} \quad (3.2)$$

Eşitlik 3.2’de j_a olarak verilen değer, j. elemana bağlı eşik değer elemanının ağırlığını gösterir. Bu eşik değer elemanının çıktısı 1’e eşittir ve bu değer sabittir.

Geriye doğru hesaplama işleminde ise hata değeri hesaplanmasıyla başlar. ($B_1, B_2, B_3...$) değerleri beklenen değer ve ($\check{C}_1, \check{C}_2, \check{C}_3 ...$) değerleri çıktı değerleri olmak üzere oluşan ($E_1, E_2, E_3 ...$) hata değerleri Eşitlik (3.3) ile hesaplanmaktadır.

$$Em = Bm - \check{C}m \quad (3.3)$$

Ağda oluşan toplam hata (TH) ise Em değerlerinin kullanılması ile aşağıdaki eşitlik 3.4 aracılığıyla hesaplanmaktadır.

$$TH = 1/2 \sum Em^2m \quad (3.4)$$

ÇKA(çok katmanlı algılayıcı) ağı eğitilirken perfonmasının yüksek ve hatanın minimum seviyede olması amaçlanmaktadır.

Bu hesaplamada ortaya çıkan hata ağırlık değerlerine dağıtılmaktadır. Ara katman ile çıktı katmanı arasındaki ağırlıklar değiştirilirken, aynı zamanda ara katmanlar arasındaki veya ara katman ile girdi katmanı arasındaki ağırlıklar değiştirilmektedir. Böylece ağırlıklarının tamamının değişmesi sağlanacaktır. İlk adım (iterasyon) ileriye ve geriye doğru hesaplamaları içermektedir. İkinci adım (iterasyon) için yeni bir örnek ağa gösterilmekte ve aynı işlemler ikinci örnek için de tekrar edilmektedir .

Ağın yapısının oluşturulmasında süreç elamanlarının sayısının belirlenmesi çok önemlidir. Kesin sayıları belli olmadığından deneme yanılma yoluyla ya da tecrübelerle dayanarak belirleme işlemi yapılabilir. Bu aşamasının atlatılabilmesi için ya çok fazla sayıda süreç elamanı katmanlara yerleştirilip kademeli azaltma ile hatanın düşürülmesine çalışılır ya da katmanlardaki süreç elamanı sayısı çok az tutulur. Kademeli olarak artırılarak hatanın azaltılmasına çalışılır. Çok katmanlı ağların gerçek hayattaki doğrusal olmayan problemlere uygun olması bunların daha çok tercih edilen olmasını sağlamıştır. Tek katmanlı algılayıcılara göre en büyük sorunu işlemlerinin çok uzun sürelerle alabilmesidir.

3.1.7.4. ÇKA ağının performansının ölçülmesi

Yapay sinir ağlarında performans değerlendirmesi öğrenme yeteneğinin hesaplanması ile bulunmaktadır. Ağın eğitim sırasında makineye sunulan tüm örnek verilere doğru cevap üretmesi performansının iyi olması anlamına gelmemektedir. Bu nedenle öğrenen ağların eğitim veri seti karşısındaki performansı yerine test için hazırlanan yeni test verisi ile beklenen performansa olup olmadığı ölçülmelidir. Bunun sebebi veri seti test ve eğitim seti olarak ayrılmaktadır. Eğitim aşamasında ağa sadece eğitim setindeki örnek veriler sunulmaktadır. Ağ eğitimi sonucunda oluşturulan ağa test verisi yüklenmektedir. (Öztemel, 2006). Ağın performansı test verisine ürettiği cevaplar üzerinden ölçülmektedir ve Eşitlik (3.5) gibi bulunur.

$$P = \frac{D}{T} \times 100 \quad (3.5)$$

D: Test setinde doğru cevap üretilen örnek veri sayısı

T: Test veri setini içeren veri sayısı

P: Performans oranıdır.

Performans kabul edilebilir oranda ve hedef düzeyde değilse ağın eğitim veri setindeki tüm örnekleri doğru cevaplamış olması ağın öğrenmiş olduğunu göstermemektedir. Bu durumda eğitim tekrarlanabilir. Eğitim adımlarının artırılması performansı istenilen düzeye getirmiyorsa örneklerin problem uzayını iyi bir şekilde temsil etmedikleri ya da ağın parametrelerinin ve topolojisinin iyi seçilmediği söylenebilmektedir (Öztemel, 2006).

3.1.7.5. ÇKA ağının öğrenmek yerine ezberlemesi

Bazı çalışmalarda eğitilen ÇKA ağı eğitim verisi bütün veri setine %100 doğru ve uygun cevap üretmesine karşın test veri setine doğru cevap üretememektedir. Bu çalışmalarda genellikle %10 veya %20 gibi bir performans ölçütü bulunmaktadır. Bu durum ÇKA ağının öğrenmediği ancak ezberlediğini göstermektedir. Çok iyi ezberleyen bir ağ oluşturmak yerine kabul edilebilir bir hata oranı ile öğrenme gerçekleştiren ağların çalışmada yer alması önemlidir. Bunun için ÇKA ağını oluştururken aşağıdaki unsurlara dikkat edilmesi önemlidir.

- Örneklerin uygun hale getirilmesi
- Girdi ve çıktıların ağa sunulması
- Girdilerin sayısal gösterimi
- Başlangıç değerlerinin atanması
- Öğrenme ve uzaklık katsayılarının belirlenmesi
- Verilerin ağa sunulması
- Ağırlıkların değişikliğe uğratma zamanlarının belirlenmesi
- Girdi ve çıktıların ölçeklendirilmesi
- Durdurma noktası oluşturulması
- Her bir katmandaki süreç elemanlarının sayısının tespit edilmesi
- Ağ yapısının geliştirilmesi ve budanması

3.1.8. Yapay sinir ağlarında öğrenme metotları

Yapay sinir ağlarında öğrenme yöntemleri genel olarak üç temel tipte sınıflandırılabilir: denetimli, denetimsiz ve takviyeli öğrenmedir.

i.Denetimli öğrenme

Denetim öğrenme kuralında ağı eğitmek için kullanılan her girdi hücresi, hedef veya istenen hücreler olan bir çıktı hücresi ile ilişkilendirilmektedir.

Modeldeki hatayı belirlemek için ağı hesaplanan ve beklenen çıktısı arasındaki fark ile öğrenme sürecinde bir öğretmenin mevcut olduğu temeline dayandırabilir. Hata değeri ağı parametrelerini değiştirmek için kullanılabilir ve bu da ilgili modelin performansının iyileşmesini sağlamaktadır.

ii.Denetimsiz öğrenme

Bu öğrenme yönteminde hedef çıktı ağı sunulmadan öğrenme beklenmektedir. Hedef örüntüleri sunacak bir öğretmen yok gibidir ve bu nedenle sistem, girdi verilerindeki öznitelikleri keşfederek ve uyum sağlayarak kendi kendine öğrenmektedir.

iii.Takviyeli öğrenme

Bu yöntemde, bir öğretmen mevcut olmasına rağmen beklenen cevabı sunmaz, sadece hesaplanan çıktının doğru mu yanlış mı olduğunu belirtir. Sağlanan bilgiler, ağı öğrenme sürecinde yardımcı olur. Hesaplanan doğru cevap için bir ödül ve yanlış bir cevap için bir ceza verilir. Ancak pekiştirilmiş öğrenme popüler öğrenme biçimlerinden biri değildir. En popüler öğrenme biçimleri olan denetimli ve denetimsiz öğrenme yöntemleri çeşitli kurallarla ifade bulmuştur. Yaygın olarak kullanılan kurallardan bazıları aşağıda sunulmuştur:

iv. Hebb öğrenme kuralı

Bu kural Hebb (1949) tarafından önerilmiştir ve bağıntılı ağırlık ayarlamasına dayanmaktadır. Bu, biyolojiden ilham alan en eski öğrenme mekanizmasıdır. Bunda, girdi-çıkı model çiftleri (X_i, Y_i), korelasyon matrisi olarak bilinen ağırlık matrisi W ile

ilişkilendirilir. Denklem 3.12 ‘deki gibi hesaplanır. (Anderson, 1983; Kosko, 1985; Lippman, 1987; Linsker, 1988).

$$\eta \frac{\delta E}{\delta W_{ij}} \quad (3.12)$$

v. Gradyan inişli öğrenme

Ağırlıklar ve ağırlık aktivasyon fonksiyonu açısından tanımlanan E hatasının minimizasyonuna dayanmaktadır. Ayrıca, ağırlık güncellemesi E hatasının gradyanına bağlı olduğundan, ağırlık tarafından kullanılan aktivasyon fonksiyonunun türevlenebilir olması gerekmektedir. Böylece, ΔW_{ij} , iki komşu katmanın i. ve j. nöronlarını bağlayan bağlantının ağırlık güncellemesi ise, ΔW_{ij} , ΔW_{ij} olarak tanımlanır. η , öğrenme oranı parametresidir ve $\partial E / \partial W_{ij}$, W_{ij} ağırlığına göre hata gradyanıdır.


vi. Rekabetçi öğrenme

Bu yöntemde, girdi uyarılarına güçlü tepki veren nöronların ağırlıkları güncellenir. Bir girdi modeli sunulduğunda, katmandaki tüm nöronlar rekabet eder ve kazanan nöron ağırlık ayarlamasından geçer. Bu nedenle, “kazanan her şeyi alır” stratejisidir.

vii. Stokastik öğrenme

Bu yöntemde ağırlıklar olasılıksal bir şekilde ayarlanır. Bir örnek, bir tür NN sistemi olan Boltzmann ve Cauchy makineleri tarafından kullanılan öğrenme mekanizması olan simüle edilmiş tavlama belirgindir.

Öğrenme algoritmalarının sınıflandırılması Şekil 3.15. 'deki gibidir.



Şekil 3.15. Öğrenim algoritmaları sınıflandırılması

3.2. Destek vektör makineleri

Destek Vektör Makinesi (DVM) ilk kez 1992'de Boser, Guyon ve Vapnik tarafından ortaya atılmıştır. Destek vektör makineleri (DVM'ler), sınıflandırma ve regresyon için kullanılan bir dizi ilgili denetimli öğrenme yöntemidir. Genelleştirilmiş doğrusal sınıflandırıcılar ailesine aittirler. Destek Vektör Makinesi (DVM), otomatik olarak verilere aşırı uymayı önlerken tahmin doğruluğunu en üst düzeye çıkarmak için makine öğrenimi teorisini kullanan bir sınıflandırma ve regresyon tahmin aracıdır. Destek Vektör makineleri, istatistiksel öğrenme teorisinden türetilmiş optimizasyon denkleminde belirli bir sapma ile yüksek boyutlu bir özellik uzayında doğrusal fonksiyonların hipotez uzayını kullanan sistemlerdir. Destek vektör makinesi başlangıçta NIPS(Nöral bilgi işleme sistemleri topluluğu) topluluğu arasında popülerdi ve şimdi dünya çapında makine öğrenimi araştırmasının aktif bir parçası haline gelmiştir.

Destek Vektör Makinelerinin (DVM) temelleri (Vapnik,1992) tarafından geliştirilmiştir ve daha iyi deneysel performans gibi birçok umut verici özellik nedeniyle popülerlik kazanmıştır. Formülasyon, geleneksel sinir ağları tarafından kullanılan geleneksel Ampirik Risk Minimizasyonu (ERM) ilkesine üstün olduğu gösterilen Yapısal Risk Minimizasyonu (SRM) ilkesini kullanır. SRM, beklenen risk üzerindeki bir üst sınırı en aza indirirken, ERM eğitim verilerindeki hatayı en aza indirir. DVM' yi istatistiksel öğrenmede amaç olan daha büyük bir genelleme yeteneği ile donatan bu farktır.

3.2.1. DVM'nin kullanım alanları

DVM'ler literatürde birçok örüntü uygulamasında olmak üzere aşağıdaki alanlarda kullanılmaktadır:

- *Yüz algılama,
- * Metin ve köprü metni sınıflandırma,
- *Görüntü sınıflandırma,
- *Biyoenformatik,
- *Protein çaprazlama

- *Uzaktan hematoloji tespiti
- *El yazısı tanıma
- *Jeoloji ve çevre bilimleri
- *Genelleştirilmiş tahmine dayalı kontrol uygulamaları gibi konularda kullanılmaktadır.(Gour, 2019).

DVM'nin uygulama alanı Şekil 3.16 de gösterilmiştir.



Şekil 3.16. DVM 'nin uygulama alanları

3.2.3. İstatistiksel öğrenme teorisi (Vapnik-chervonenkis teorisi)

İstatistiksel öğrenme teorisi, 1960'lı yılların sonlarında Vladimir Vapnik ve Alexey Chervonenkis tarafından oluşturulmuştur. 1990'lı yıllara kadar sadece veri toplama ve verilerden fonksiyonel yapı tahmin etme problemlerinde analiz olarak kullanılmıştır. 1992'de ise yeni bir öğrenme algoritması DVM sunulmuş ve istatistiksel öğrenme teorisi daha yaygın biçimde kullanılmaya başlanmıştır.

Vapnik (1992), istatistiksel teorinin gerekliliği ile ilgili olarak: “hiçbir şey, iyi bir teoriden daha pratik değildir” demiştir, bu sözleriyle fonksiyonel ve matematiksel yapının önemine vurgu yapmıştır. İstatistiksel öğrenme teorisi, istatistiksel bakış açısı ile öğrenme işlemini açıklamayı amaçlayan hesaplamalı öğrenme kuramının bir türü olarak ifade

edilebilir. İstatistiksel öğrenme teorisinde amaç dağılımdan bağımsız olan yöntemleri kullanarak sınıflandırma ve tahmin yapmak için hata sınırlarını üreterek küçük hacimli anakütleler arasında istatistiksel ilişkileri araştırmaktadır. Teoride, veri kümelerinin üzerindeki spesifik hata ile ilgilenilmez genelleme hatasının karakterize edilmesi üzerinde durulmaktadır.

Klasik istatistiksel bakış açısı doğru model ünitesinin bilindiğini varsayar ve modelin parametrelerini belirlemeye çalışır. İstatistiksel öğrenme teorisi ise klasik istatistiğin tersine model biçiminin bilinmediğini kabul ederek, doğruluk olasılığı yüksek modeller arasında en uygun model belirlemeye çalışmaktadır.

İstatistiksel öğrenme teorisinin temelini oluşturan iki varsayım aşağıda belirtilmiştir:


- i. Test verileri ile eğitim verileri arasında ilişki olduğu varsayımı
- ii. Test verileri ile eğitim verilerinin aynı dağılımdan geldiği ve birbirinden bağımsız olduğu varsayımdır. Bağımsızlık varsayımında her yeni bilgi en çok bilgiyi sağlar ve aynı dağılım varsayımı ise olasılık dağılımı hakkında bilgi vermektedir.

İstatistik teorisinde modelleme yapılırken hipotez uzayından hedef uzayına uzanan dayanak (underlying) fonksiyonuna en yakın model seçilmektedir. İlgili model seçiminde iki tür hata söz konusudur (Gunn,1998).

Yaklaşım Hatası: Hipotez uzayının hedef uzaydan daha küçük olmasının bir sonucudur. Bu nedenle alttaki fonksiyon, hipotez uzayının dışında kalabilir. Model uzayının kötü seçilmesi, daha büyük yaklaşıklık hatasını ortaya çıkarır ve bu durum uyumsuzluğu olarak adlandırılır.

Tahmin Hatası: Bir tekniğin hipotez uzayından en uygun (optimal) olmayan modeli seçmesiyle sonuçlanan öğrenme kuralından kaynaklanan hata olarak ifade edilmektedir.

Model hatalarının ifadesi Şekil 3.24 'de verilmiştir.



Şekil 3.17. Model hataları

Bu hatalar birlikte genelleme hatasını ortaya çıkarmaktadır. Sonuç olarak, riski en aza indiren f fonksiyonunu bulunması istenir. Bu fonksiyon (3.6) eşitliğinde ifade edilmiştir.

$$R[f] = \int L(y, f(x))P(x, y) dx dy \quad (3.6)$$

$P(x, y)$ bilinmiyor ve Ampirik risk minimizasyon ilkesine göre bir yaklaşım bulunur,

$$R_{emp}[f] = \frac{1}{l} \sum_{i=1}^l L(y^i, f(x^i)) \quad (3.7)$$

Ampirik riski en aza indiren ifade eşitlik 3.7'deki gibidir.

$$\hat{f}_{n,1}(x) = \arg \min_{f \in \mathcal{X}_n} R_{emp}[f] \quad (3.8)$$

Ampirik risk minimizasyonu ancak eşitlik 3.8 'de ki durumlarda anlamlıdır:

$$\lim_{l \rightarrow \infty} R_{emp}[f] = R[f] \quad (3.9)$$

Büyük sayılar yasasından doğrudur. Ancak, optimal olması gerekmektedir. Eşitlik 3.10'de verilmiştir.

$$\lim_{l \rightarrow \infty} R_{emp}[f] = \min_{f \in \mathcal{X}_n} R[f] \quad (3.10)$$

Sadece $\mathcal{X}_n$ yeterince 'küçük' olduğunda geçerlidir. Bu koşul daha az sezgiseldir ve minimumların da yakınsamasını gerektirir. Eşitlik 3.11 ifadesi $1 - \delta$ olasılığı ile geçerlidir.

$$R[f] \leq R_{emp}[f] + \sqrt{\frac{h \ln \left(\frac{2l}{h} + 1 \right) - \ln \left(\frac{\delta}{4} \right)}{l}} \quad (3.11)$$


Beklenen risk için eşitlik 3.11 olasılık dağılımından bağımsızdır.

İyi bir eğitim gerçekleştirebilmek için büyük eğitim verisinin kullanılması gerekir. Bunun nedeni, eğitim veri kümesinin yeterince büyük olması durumunda, eğitim hatası sıfıra yakın olabilir. Kecman (2001), örneklem boyutunu belirlemede eğitim verisi sayısının VC (Vapnik- Chervonenkis) boyutuna olan oranı ölçü olarak kullanmıştır. Oran değeri **20'den küçük** çıkan veri kümelerine küçük, **20'den büyük** çıkanlar ise orta ölçekli veri kümeleri olarak değerlendirmiştir. Genelleme hatası ve büyük veri setleri DVM nin ortaya çıkışını hızlandırmıştır. DVM istatistiksel öğrenme metodolojisi altında yüksek boyutlu ve küçük sayıda eğitim ile bu sorunların çözümünde kullanılmıştır. Sonlu örnek kütlelerinde bağımlılıkların tahmin edilmesii için genel bir teori olarak kabul edilen istatistiksel öğrenme teorisi; VC boyutu ve yapısal risk minimizasyonu kurallarıyla öğrenmeyi amaçlamaktadır.

3.2.3.1. VC boyutu

Vapnik–Chervonenkis teorisi (VC teorisi olarak da bilinir) 1960–1990 yılları arasında Vladimir Vapnik ve Alexey Chervonenkis tarafından geliştirilmiştir. Teori, öğrenme sürecini istatistiksel bir bakış açısıyla açıklamaya çalışan bir hesaplamalı öğrenme teorisi biçimidir. VC teorisi, istatistiksel öğrenme teorisi ve ampirik süreçlerle ilgilidir (Vapnik, 2000).

VC boyutu, bir dizi işlevin kapasitesini ölçen skaler bir değerdir. VC boyutu grafiği Şekil 3.25'te verilmiştir.



Şekil 3.18. VC boyutu

VC Teorisi: Bir dizi fonksiyonun VC boyutu, ancak ve ancak, bu noktaların olası tüm p^2 konfigürasyonlarında ayrılabilirliği bir $\{x^i\}_{i=1}^p$ noktaları kümesi varsa ve $q > p$ 'nin bu özelliği sağladığı yerde hiçbir $\{x^i\}_{i=1}^p$ kümesi mevcut değilse, p 'dir.

Şekil 3.25, düzlemdeki üç noktanın doğrusal gösterge fonksiyonları seti tarafından nasıl parçalanabileceğini gösterirken dört noktanın nasıl parçalanamayacağını göstermektedir. Bu durumda VC boyutu, serbest parametre sayısına eşittir. Ancak genel olarak durum böyle değildir; Örneğin $\sin(bx)$ fonksiyonu sonsuz bir VC boyutuna sahiptir (Vapnik, 1995). n boyutlu uzayda doğrusal gösterge fonksiyonları seti, $n + 1$ 'e eşit bir VC boyutuna sahiptir.

3.2.3.2. Yapısal risk minimizasyonu (YRM)

S_h , h VC boyutunun bir hipotez uzayı olacak şekilde bir yapı oluşturulur.

$$S_1 \subset S_2 \subset \dots \subset S_\infty \quad (3.12)$$


YRM, eşitlik 3.13 'deki problemin çözülmesidir.

$$\min_{S_h} R_{emp} + \sqrt{\frac{h \ln\left(\frac{2l}{h} + 1\right) - \ln\left(\frac{\delta}{4}\right)}{l}} \quad (3.13)$$

Modellenen temel süreç deterministik değilse, modelleme problemi daha zorlayıcı hale gelir ve sonuç olarak bu bölüm deterministik süreçlerle sınırlıdır. Çoklu çıktı sorunları genellikle bağımsız olarak kabul edilebilecek bir dizi tek çıktı sorununa indirgenebilir. Bu nedenle, tek bir çıktının tahmin edilmesinin istendiği birden çok girdiye sahip süreçleri göz önünde bulundurmak uygun olmaktadır (Gunn,1998).

3.2.4. DVM sınıflandırma

Sınıflandırma problemi, genelliği kaybetmeden iki sınıflı problemin dikkate alınmasıyla sınırlandırılabilir. Problem amacı, var olan örneklerden türetilen bir fonksiyon ile iki sınıfı ayırmaktır. Amaç, görünmeyen örnekler üzerinde iyi çalışacak, iyi genelleme yapabilecek, bir sınıflandırıcı üretmektir. DVM ile optimal sınıflandırma düzlemi Şekil 3.26 'da gösterilmiştir.




Şekil 3.19. Optimal sınıflandırma düzlemi

Şekil 3.19 ‘da, verileri ayırabilen birçok olası doğrusal sınıflandırıcı vardır. Ancak marjı (bu sınıfla her sınıfın en yakın veri noktası arasındaki mesafeyi en üst düzeye çıkarır) en üst düzeye çıkaran yalnızca bir tane vardır. Doğrusal sınıflandırıcı, optimal ayırma hiperdüzlemi olarak adlandırılmaktadır. Sezgisel olarak, bu sınırın diğer olası sınırların aksine iyi bir şekilde genellenmesi beklenmektedir (Gunn,1998).

3.2.4.1. Doğrusal ayrılabilen DVM sınıflandırması

Gerçek hayattaki veriler oldukça karmaşık yapıya sahiptir. Doğrusal ayrılabilen verilere sıklıkla karşılanmamaktadır. Destek Vektör Makinelerinin doğrusallık durumu ise doğrusal olarak ayrılabilen veriler için uygulanmaktadır. Doğrusal olarak ayrılabilen problemler DVM’nin temel yapısını oluşturmaktadır.



Şekil 3.20. Doğrusal olarak ayrılma durumu


Şekil 3.20’de ki doğrusal ayrılabilen verilerden oluşur ve aralarında birçok hiperdüzlem çizilebilmektedir. DVM Şekil 3.27’de oluşan tüm hiperdüzlemlerden minimum olanı seçmektedir. Minimum düzeyde seçilen hiperdüzlem her iki sınıfa eşit uzaklıktadır. Her N elemandan oluşan verinin $X=\{x_i, y_i\}$ $i=1,2,3,...,N$ olduğu varsayalım. Burada, $y_i \in \{-1,1\}$ değerleri ve $x_i \in \mathbb{R}$ özellikler vektörünü oluşturmaktadır. Bu iki veri doğrusal ayrılabilme durumunda aşırı düzlem ile ayrılabilir. DVM bu durumda aşırı düzlemleri iki gruba eşit uzaklıkta olmasını sağlamaktadır. Aşırı düzlem üzerindeki bir x noktası, w aşırı düzlemin normali ve $|b|/|w|$ uzayının orijine dik uzaklığı olmak üzere Eşitlik 3.14 şartı sağlanır. (Akşehirli,2013)

$$w \cdot x + b = 0 \quad (3.14)$$

Eşitlik 3.14 ‘da yer alan w : hiper düzlemin normalini ve b : yanlılığı belirtmektedir. X ise bu düzlem üzerinde herhangi bir noktadır. Burada $w \cdot x$ çarpımı bir iç çarpımı ifade etmektedir. DVM’de iki sınıfı en uygun ayırmada hiper düzlemi bulmak için kareli optimizasyon probleminin çözümünde Lagrange çarpanlarından yararlanılmaktadır. Lagrange çarpanları, küçükleme tipinde olan problemi ikili (dual) probleme dönüştür ve ilgilenilen problemin daha basit olarak çözümlenmesini sağlamaktadır (Akşehirli,2013).

3.2.4.2. Doğrusal ayrılmayan DVM sınıflandırması

Destek Vektör Makineleri (DVM), doğrusal olarak ayrılmayan problemler olması durumunda orijinal veriler yardımıyla sınıflandırma yapabilmek üzere doğrusal olmayan haritalama yapar ve n boyutlu girdi uzayından daha yüksek boyutlu nitelik uzayına taşımaktadır. DVM nitelik uzayında en iyi eş uzaklık marjini belirleyebilmek için doğrusal sınıflandırma kuralını uygulamaktadır. Bu kural ile nitelik uzayında doğrusal olması durumuna karşın, ilk girdi uzayına izdüşüm yapıldığında doğrusal değildir. Doğrusal ayrılmayan verilerle DVM nitelik uzayına taşındığında burada doğrusal DVM gibi davranabilmektedir. Bu şekilde nitelik uzayında ve en iyi şekilde ayıracak hiper düzlemi aramaktadır (Küçüksille vd.,2013). Doğrusal ayrılmayan verilerin yüksek dereceli örnek uzayına aktarılması Şekil 3.21 ‘de verilmiştir.



Şekil 3.21. Doğrusal ayrılamayan verilerin yüksek dereceli nitelik uzayına aktarılması (Güneren,2015)

3.2.4.3. Kernel fonksiyon çeşitleri

Destek vektör makineleri genellikle, doğrusal olmayan iki sınıf arasındaki optimum hiperdüzlemi bulabilmek için, verileri giriş uzayından daha yüksek boyut içeren nitelik uzayına haritalama tekniğiyle taşımaktadır. Haritalama tekniğinde kullanılacak fonksiyonu bilmek veya elde etmek genellikle zor olabilmektedir. Bu sebeple, haritalama işlemini yapmak için çekirdek fonksiyonlarından faydalanılmaktadır. Çekirdek fonksiyonları, elde edilmiş veya bilinir bir haritalama fonksiyonu olmadan yüksek boyutlu uzayda nokta çarpımları hesaplayabilir ve tanımlayıcı nitelik uzayındaki iç çarpımı gerçekleştirmektedir. Bu sayede Φ dönüşümünün analitik olarak bilinmesine gerek kalmamaktadır(Tan,2004). Oluşan vektörler yüksek boyutlu tanımlayıcı nitelik uzayına net olarak haritalayıp iç çarpım hesaplanması yerine çekirdek fonksiyonu yardımıyla doğrudan iki vektörün iç çarpımını yapılacaktır. Haritalama fonksiyonlarının bilinmediği durumlarda girdi uzayındaki veriler yolu ile elde edilen bir çekirdek fonksiyonu elde edilerek işlemler gerçekleştirilmektedir. Doğrusal olarak ayrılamayan verilerde kullanılan DVM metodunun performansı, sınıflandırma yapılırken seçilmesi gereken çekirdek fonksiyonu ile doğrudan ilgisi vardır. Çekirdek fonksiyonları girdi uzayındaki bileşenlerin çoğunu belirli bir kurala göre dönüştürülmesinde rol oynar. Böylece çekirdek fonksiyonlarına yer veren metotlar girdi uzayında karmaşık olan birçok uygulama üzerinde de çalışabilme imkanı vermektedir.(Kwok,2003)

DVM'ler farklı türdeki çekirdek fonksiyonu ile çeşitlenebilir ve bu da farklı sınıflama performanslarına sebep olabilmektedir. Birden fazla çekirdek fonksiyonlar literatürde yer almaktadır. En çok kullanılan fonksiyon çeşitleri; doğrusal fonksiyon, polinomiyal fonksiyon, sigmoid fonksiyon ve radyal tabanlı fonksiyon (RTF)'dur. Polinomiyal çekirdek fonksiyon, RTF'ye göre daha fazla parametre içermektedir. Bu nedenle, RTF'nin hesaplanabilmesi daha basit ve temeldir. Fakat, düşük derecelerde polinomiyal çekirdek fonksiyon ile iyi sonuçlar alınabiliyorsa polinomiyal çekirdek, sınıflandırılmayan kısımlar mevcut ise ceza parametresi sebebiyle RTF kullanılması doğru olacaktır. Doğrusal çekirdek fonksiyon ise, özellik sayısının birden çok fazla olduğu çalışmalarda performansı yüksek sonuçlar vermektedir. (Çomak, 2008)

Literatürde kullanılan çekirdek fonksiyonlar Tablo 4.2'de gösterilmektedir.

Çizelge 3.2. Çekirdek fonksiyonlarının genel gösterimi

Çekirdek Fonksiyon İsimleri	Çekirdek Fonksiyonların Yapısal Formu
Doğrusal Fonksiyon	$K(x_i, x_j) = x_i^T x_j$
Polinomiyal Fonksiyon	$K(x_i, x_j) = (1 + x_i^T x_j)^d$
Sigmoid Fonksiyon	$K(x_i, x_j) = \tanh(kx_i^T x_j - \delta)$
Radyal Tabanlı Fonksiyon	$K(x_i, x_j) = \exp(-\frac{\ x_i - x_j\ ^2}{2\gamma^2})$
Üstel Yarıçaplı Fonksiyon	$K(x_i, x_j) = \exp(-\frac{\ x_i - x_j\ ^2}{2\sigma^2})$
Ters İkinci Dereceden Fonksiyon	$K(x_i, x_j) = (\ x_i - x_j\ ^2 - c^2)^{-1/2}$
B-spline	$K(x_i, x_j) = B_{2n+1}(x_i - x_j)$

3.2.4.4. Hiperparametrelerin seçimi

DVM'nin performans başarısı, hatalı sınıflama maliyetinin cezası veya ölçüsü olarak adlandırdığımız C parametresine, verilerin tamamının doğrusal ayrılamadığı durumlarda işlenen γ parametresine ve çekirdek fonksiyonlardaki diğer parametrelerin seçimi ile doğrudan etkilenmektedir. Bu parametrelerin tamamı hiperparametre olarak isimlendirilmektedir. Hiperparametrelerin en iyi şekilde seçilmesi, DVM'nin veriyi en uygun şekilde sınıflamasını sağlamaktadır. Eğitim hatası ve VC boyutu arasındaki

ödünleşimin belirleyici unsuru C ve ξ parametreleri, çalışmacılar tarafından seçilmektedir. C parametresi $0 < C < \infty$ aralığında yer alır ve uygulayıcılar tarafından rastsal olarak seçilmektedir. C değeri çok büyük seçilirse, ayrılamayan noktalar için yüksek bir hata söz konusu olacağından çok fazla destek vektöre ihtiyaç duyulacaktır ve bu da aşırı uyuma (overfitting) neden olmaktadır. C değerinin çok küçük seçimi ise eksik uyuma (underfitting) neden olabilmektedir.




4. BULGULAR VE TARTIŞMA

Çalışmanın bu bölümünde araştırma konusu, araştırma örneklemi, analiz türleri verinin elde edilmesi ve analizi ile ilgili bilgiler içermektedir.

4.1. Prostat

Prostat üriner sistemin son kesimine yakın mesafede mesane ve üretra (dış idrar kanalı) arasında bulunan ceviz büyüklüğünde bir organ olarak tanımlanır. Yapısal formu üretral kret, seminal kolikulus, boşalma kanalı, prostatik sinüs, prostatatik kanallar, prostatik utrikülden oluşur. Prostat erkeklerde yer alan bir organ olmasına karşın kadınlardaki benzer organ Skene bezidir.(tr.wikipedia.org,2022). Prostat bezinin görevlerini yerine getirebilmesi için vücuttaki erkeklik hormonlarına ihtiyacı vardır. Vücuttaki erkeklik hormonun merkezi testislerdir ve ‘Testosteron’ hormonu üretmekle görevlidirler. Diğer erkeklik hormonları ise sürrenal, adrenal(böbreküstü bezleri) bezlerinin yardımıyla üretilir. (uroonkoloji.org,2022) Şekil 4.1. de prostat ve komşu yapılar gösterilmiştir.



Şekil 4.1. Prostat ve komşu yapılar

Prostat organının yapısal işleyişinin temelinde iki ana görevi bulunmaktadır. En temel fonksiyonu idrar atımı sırasında idrar torbasından idrarı taşımak olup meninin dışarı atılması durumu sırasında ise spermin taşınmasında rol oynamaktır. Aynı zamanda meni

nin içinde var olan, spermleri doyuran ve bunları kadın üreme organı içerisinde ilerlemesi esnasında sağlamlığını oluşturan kendine özgü bir protein üretmektedir. (tr.wikipedia.org,2022)

4.1.1. Prostat hastalıkları

Prostat bezinde sıklıkla rastlanan rahatsızlıklar; iyi huylu büyüme (Benign Prostat Hiperplazisi), prostat enfeksiyonları (prostatit) ve prostat kanseri(Malign Prostat Hiperplazisi)'dir.


4.1.2 İyi huylu prostat büyümesi

İyi huylu prostat büyümesi (BPH) zamanla artarak bir halk sağlığı sorunu olarak zamanımızda yerini almaktadır. Otopsi çalışmalarında araştırmacıların ortaya konan yüksek mikroskopik BPH verilerinin yanında epidemiyolojik araştırmalarda da alt üriner sistem şikayetleri 50 yaş üzeri erkeklerde %25-30 gibi yüksek bir oranda mevcut olduğu bilinmektedir (Oelke vd. 2005) İyi huylu prostat oluşumunun sebebi net olarak bilinmemektedir. Bunun sebebi ise risk faktörlerinin tam anlamıyla ne olduğunun anlaşılamamasından kaynaklanmaktadır. Genel olarak en önemli bilgi iyi huylu prostat büyümesi yaşlı(BPH) erkeklerde olduğu ve ergenlik çağından önce bir nedenle testisleri (yumurtaları) alınması zorunda kalmış erkeklerde ise BPH'ın gelişmediğidir. Bu sebeple yaş ve testis fonksiyonu ile ilgili faktörlerin BPH gelişiminde önemli olduğu düşünülmektedir.(Tunç,2022)

4.1.3. Prostat kanseri

Dünya Sağlık Örgütü'nün (DSÖ) 2020 yılında sunmuş olduğu rapora göre global kanser verilerini içeren GLOBOCAN 2020 sonuçlarında prostat kanseri erkeklerde en sık karşılaşılan ikinci kanser olduğu belirtilmiştir. Rapora göre erkeklerde güncel tanı alan kanserlerin yüzde 14,1'ini ve tüm ülkelerde her yıl 1.4 milyon erkeğe bu da yaklaşık 1 buçuk milyon erkeğe prostat kanseri teşhis edildiği bildiride yer verilmiştir. Yayınlanan bildirideki veriler göz önüne alındığında dünyada her yıl 375 bin erkek prostat kanseri

sebebiyle yaşamlarını yitirmektedirler. DSÖ'nün GLOBOCAN raporuna göre 2020 yılı baz alındığında Türkiye'de 19 bin 444 erkeğe prostat kanseri tanısı konmuştur. Şekil 4.2 'de 2020'deki yeni kanser sayıları her yaştan ve cinsiyetten kanser tür dağılımı sunulmuştur.



Şekil 4.2. 2020 yılı kanser vakaları ve dağılımı

Şekil 4.2'de görüldüğü üzere 2020 yılı içinde dünyada yüzde 7.3 erkek prostat kanserine yakalanmıştır.

4.1.4. Prostat kanseri tanı ve tedavi

İnsan vücudunun doğasında birbirine benzemeyen bir çok hücre yapısı vardır. Sağlıklı olarak nitelendirdiğimiz bir bireyde vücudun ihtiyacına bağlı olarak hücreler bölünerek çoğalmakta ve görevlerini yapıktan sonra ise parçalara ayrılarak yok olmaktadır. Hücre bölümleri gereksinim olmadığı halde bölünmelerine devam edilirse yeni oluşacak hücre yeni dokularıda oluşturur. Bu durum dokudaki aşırı büyüme ile sonuçlanır ve tümör olarak nitelendirilir. Tümör dokusu iyi huylu (benign) veya kötü huylu (malign) olarak ikiye ayrılmaktadır. İyi huylu tümör dokuları kanser hücreleri içermez ve vücudun diğer dokularına dağılmamaktadır.

Malign yapılı tümör dokuları kanser özelliklerini içermektedir. Kanser hücreleri kontrolsüz bir şekilde çoğalarak vücudun diğer dokularına dağılmaktadır. Kanserli dokulardan bölünen hücreler kan veya lenf dolaşımlarıyla vücudun farklı bölümlerine geçiş yaparlar ve bu sayede yeni kanser merkezleri oluşturmaktadırlar. Kanser odak noktasından başka doku ve organlara dağılması metastaz olarak adlandırılır. Kanser hastalığı olduğu organ ve hücrenin çeşidine göre isimlendirilmektedir. (uroonkoloji.org,2022)

Prostat kanseri sinsi ilerleyen ve genellikle hastalığın ilk periyodunda herhangi bir yakınmaya neden olmamaktadır.. Bu hastalıkta genel yakınmalar;

- Geceleri tekrarlayan idrar yapma gereksinimi,
- İdrar atılmasında gecikme ve bitiminde idrarın bir kısmının atılmaya devam etmesi ,
- İdrar yapmakta zorlanma yada hiç idrar yapamamak,
- İdrar atılımı esnasında yankı veya ağrı hissetmek,
- Cinsel ilişki durumunda ağrılı ,acılı ejakülasyon (boşalma),
- İdrar veya menide kan ile karşılaşılmasıdır.

Üroloji doktoruna idrar yapma zorluğu şikayeti ile gelen kişinin önce hastalık öyküsü dinlenir ve daha sonra fiziki muaneyeye geçilir.Hekim gerek duyduğu takdirde bazı labararatuvar tetkikleri istemektedir.Ön muayane aşamasında fiziki muayene ve kan tahlilleri aşağıdaki gibi gerçekleşmektedir.

- Parmakla Rektal Muayene
- Kan Testleri
- İdrar Tahlili

- Transrektal Ultrasonografi
- Prostat biyopsisi

Prostat kanserinin hangi evrede olduğunu tespit etmek için derecelendirme yapılmaktadır. Bu derecelendirmede 'Gleason Skorlama' sistemi üzerinden gerçekleştirilmektedir. Prostat kanseri bu sistemle 2 ile 10 arasında derecelendirmeye tabi tutulmaktadır. Düşük dereceli seyreden tümör dokuları büyük dereceli tümörlere göre daha yavaş gelişme ve metazdas niteliğine sahiptir. (uroonkoloji.org,2022)

4.2. Araştırma Evreni ve Örneklemi

Araştırma örneklemini örnek hacmi hesaplamasında, "*Tek Örneklem Oran*" testine göre hesaplama yapılmıştır. I. tip hata düzeyi % 5 olacak şekilde, güç düzeyi ise %80 ile %95 arasında olacak şekilde hesaplamalar gerçekleştirilmiştir. Çalışmada; 2010 yılından itibaren ESOĞÜ hastanesine başvuran hastaların "Prostat" tanılı olanların sayısı 65921 ve bu hastaların ise 25296 tanesi ise "Prostat Malign Neoplazmi" tanılı olanlar hesaplanmıştır. Bu Kohasta sayıları ile görülme sıklığı hesaplandığında %38.37 olduğu belirlenmiştir. Çalışmada alternatif hipotez olarak, ESOĞÜ hastanesinde görülme sıklığı olarak %40 değeri kriter değeri olarak kabul edilerek hesaplamalar gerçekleştirilmiştir. Örnek hacmi hesaplanması PASS 11.0 paket programında hesaplanmıştır. Örneklem değişken ilişkileri dikkate alınarak birincil ve ikincil örneklem olarak planlanmıştır. Birincil örneklem 1268 hacimli "Prostat Malign Neoplazmi" tanılı hasta grubu ve "Prostat Belign Hiperplazi" tanılı hasta grubu 523 hacimli belirlenmiştir. İkincil örneklem de 30 hacimli "Prostat Malign Neoplazma" tanılı hasta grubu ve "Prostat Belign Hiperplazi" tanılı hasta grubu 30 hacimli belirlenmiştir.

4.3. Veri Toplama Tekniği

Çalışmamız kohort retrospektif bilimsel araştırmadır. Kohort, ortak niteliklerden hastaların oluşturduğu grup anlamına gelmektedir. Belirli bir zamandan geçmiş bir

zamana doğru kohort deneklerini gözlenmesine ise retrospektif kohort çalışmaları adını almaktadır. Çalışmada geçmişe dönük kayıtlı verilerden yararlanılmıştır.

4.4. Değişkenler

Çalışmada kullanılan değişkenler ve değişken özellikleri aşağıda belirtilmiştir.

- **BLD:** İdrar tahlil sonucunda kan görüldüğünü gösteren bir ifadedir. Sonuçta “++” olması ise pozitif anlamına gelir ve kanın miktarını gösteren bir bilgidir.
- **GLU:** İdrar tahlil sonucunda şeker görülmesi durumudur. Sonucunda “+” ifadesi şeker kaçağı olarak tanımlanmaktadır.
- **KET:**Keton idrar tahlilinde gözlemlenen başka bir parametredir. Herhangi bir sebeple vücut enerji için yeterli glikoz alamıyor ve vücut yağlarını kullanmaya başlıyor ise vücuttaki ketonlarda artışa neden olmaktadır. Bu durum normalden fazla keton çıkmasına sebep olabilmektedir.
- **LEU:**İdrardaki lökosit miktarını ifade eder.Lökosit savunma hücresi olan akyuvarlardan oluşmaktadır.
- **NIT:**İdrarda ki enfeksiyondan sorumlu bakterilerin varlığını gösteren parametrelerden biridir.
- **PH:**Vücudun asit- baz dengesini gösteren idrar parametresidir.
- **PRO:**İdrardaki protein seviyesini temsil etmektedir.
- **SG:** İdrar yoğunluğunu gösteren bir ifadedir.
- **URO:**Karaciğer fonksiyonel yapısını etkileyen yapılardan biri olan üronobilijendir.
- **PSA:** Prostatta üretilen, meninin kıvamını düzenlenmesinde görev alan bir enzimdir. Çok az veya fazla salgılanması prostat hastalıklarının göstergesidir.
- **LDL:** Kanda ki halk dilinde kötü kolesterol seviyesinin göstergesi olarak kabul edilir.
- **ALKALEN FOSFATAZ:** vücudumuzda özellikle iskelet sistemi ve sindirim sisteminde yoğun olarak üretilen bir enzimdir.

4.5. Uygulama

4.5.1. Birincil örneklem bulgular

4.5.1.1. Birincil örneklem betimsel inceleme


Birincil örneklem PRO, URO, GLU, LEU, BLD kategorik idrar tetkiki değişkenleri ve PSA, SG, PH değişkenlerinden oluşmaktadır.

	Hastalık Türü	N	M	SD
PH	Prostat Kanseri	884	0,7432	0,71325
	Prostat Büyümesi	487	5,7341	0,71336
SG	Prostat Kanseri	884	2,1509	33,7723
	Prostat Büyümesi	487	1,0141	0,00606
PSA	Prostat Kanseri	884	5,4179	5,08904
	Prostat Büyümesi	487	3,2982	4,70855

Çizelge 4.1. Nümerik değişkenlerin betimsel istatistikleri

Çizelge 4.3 'de PH nümerik değişkenin hastalıklar arasında ortalama bir fark gözükmemektedir. SG değişkenin prostat kanserindeki ortalaması (M=2.15) ile prostat büyümesinden büyük olduğu gözükmemektedir. PSA değişkenin ortalaması prostat kanserinde ortalaması (M= 5.42) ile prostat büyümesinden daha yüksektir. PSA tahlili her 5 yılda bir kontrolü sağlanan ve prostat kanseri tanısı için önemli bir parametredir. 40 yaşını aşmış her bireyde gözlenebilmektedir. Çok nadirde olsa 18 yaşında büyüme ve kanser vakaları DSÖ tarafından açıklanmıştır.

Kategorik değişkenlerin frekans dağılımları Şekil4.3'de verilmiştir.



Şekil 4.3. Kategorik değişkenlerin frekans grafikleri

4.5.1.2. Birincil örneklem yapay sinir ağları sınıflandırma bulguları

Birincil örneklem %64'ü prostat kanseri ve %36'sı prostat büyümesi verilerinden oluşmaktadır.

Analiz Python yazılım dilinde veriler notebook çalışma sayfasında sclearn kütüphanesi üzerinde çalışma kodlar bloğu ile yapılmıştır. Veriler %30 test ,%70 eğitim seti olarak ayrılmıştır.

Parametre Uzayı	
Gizli Katman Sayısı	(10,30,10)(20,10),(5,)
Aktivasyon Fonksiyonu	Tanh,Relu
Alpha	(0.001,0.1)
Öğrenim Hızı	Adaptive

Çizelge 4.2. Yapay Sinir Ağlarında Oluşturulan Parametre Uzayı

Çizelge 4.4’de test aşamasında öğrenme hızı adaptive dinamik olarak azalarak öğrenme biçimi üzerinden yapılmıştır. Aktivasyon fonksiyonları tanh ve relu olarak iki ayrı aktivasyon fonksiyonunda test için 100 adet model oluşturulmuştur.

Oluşturulan sınıflandırma modellerinden en iyi model seçimi sclearn kütüphanesi ile optimize edilmiştir. Seçilen en iyi modelin parametreleri Çizelge 4.4’de verilmiştir.

Gizli Katman sayısı	10
Aktivasyon fonksiyonu	Tanh
Alpha	0.001
İterasyon	100

Çizelge 4.3. En İyi Sınıflandırma Modelinin Parametre Uzayı

	Gerçek Pozitif	Gerçek Negatif
Tahmin Pozitif	222	42
Tahmin Negatif	104	44

Çizelge 4.4. En İyi Sınıflandırma Modelinin Hata Matrisi

Doğruluk	0.645631
Kesinlik	0.680982
Duyarlılık	0.840909
F1 Score	0.752542
Özgüllük	0.840909
Hasasiyet	0.297297
Cohen Kappa	0.152216
Eğitim Süresi	0.386880
Değer alma süresi	0.003392

Çizelge 4.5. Yapay Sinir Ağlarında Sınıflandırma Sonuç Metrikleri

4.5.1.3. Birincil örneklem destek vektör makineleri sınıflandırma bulguları

Hiperparametre Uzayı	
Ceza Parametresi	(1,10)
Gamma	(0.01,0.001)
Derece	2,3
Çekirdek	Rbf, Poly, Sigmoid, Linear

Çizelge 4.6. DVM Sınıflandırma Hiperparametre Uzayı

Derece	Ceza Parametresi	Gamma	Kernel	Toplam Zaman
2	1	0.01	Rbf	0.0s
2	1	0.01	Poly	0.3s
2	1	0.01	Poly	0.1
2	1	0.01	Sigmoid	0.0s
2	1	0.01	Sigmoid	0.0s
2	1	0.01	Linear	1.0s
2	1	0.01	Linear	0.6s
2	1	0.01	Linear	1.2s
2	1	0.001	Rbf	0.0s
2	1	0.001	Rbf	0.0s
2	1	0.001	Rbf	0.0s
2	1	0.001	Poly	0.0s
2	1	0.001	Poly	0.0s
2	1	0.001	Poly	0.0s
2	1	0.001	Sigmoid	0.0s
2	1	0.001	Sigmoid	0.0s
2	1	0.001	Sigmoid	0.0s
2	1	0.001	Linear	2.0s
2	1	0.001	Sigmoid	2.2s
3	1	0.01	Rbf	0.0s
3	1	0.01	Rbf	0.0s
3	1	0.01	Poly	16.9s
3	1	0.01	Poly	23.0s
3	1	0.01	Sigmoid	0.0s
3	1	0.01	Sigmoid	0.0s
3	1	0.01	Linear	1.1s
3	1	0.01	Linear	1.6s
3	1	0.001	Rbf	0.0s
3	1	0.001	Poly	0.0s
3	1	0.001	Sigmoid	0.0s
3	1	0.001	Linear	1.3s
2	10	0.01	Rbf	0.0s
2	10	0.01	Poly	1.8s
2	10	0.001	Sigmoid	1.5s
2	10	0.001	Linear	2.9s
3	10	0.01	Rbf	0.0s
3	10	0.01	Poly	2.5min
3	10	0.001	Sigmoid	0.0s
3	10	0.001	Linear	3.1s

Çizelge 4.7. DVM Sınıflandırma Üretilen Modeller

Hiperparametre		Test Doğruluğu	Eğitim Doğruluğu
Ceza Parametresi	10		
Derece	3	0.68	0.77
Gamma	0.01		
Kernel	Poly		

Çizelge 4.8. DVM Sınıflandırma En İyi Model ve Doğruluk Ölçütü

	Gerçek Pozitif	Gerçek Negatif
Tahmin Pozitif	216	48
Tahmin Negatif	84	64

Çizelge 4.9. DVM Sınıflandırma Hata Matrisi

Doğruluk	0.679612
Kesinlik	0.720000
Duyarlılık	0.818182
F1 Score	0.765957
Özgüllük	0.818182
Hasasiyet	0.432432
Cohen Kappa	0.264763
Eğitim Süresi	85.00000
Değer alma süresi	0.006910

Çizelge 4.10. DVM Sınıflandırma Model Sonuç Metrikleri

4.5.2. İkincil Örneklem Bulgular

4.5.2.1. İkincil örneklem betimsel inceleme

	Hastalık	N	M	SD
Yaş	Prostat Kanseri	300	74,4817	9,6314
	Prostat Büyümesi	29	75,5862	7,6882
Ldl	Prostat Kanseri	300	126,7389	46,57963
	Prostat Büyümesi	29	128,4621	49,91458
Psa	Prostat Kanseri	300	48,251	235,90127
	Prostat Büyümesi	29	29,0376	76,50339
Alkalen Fosfataz	Prostat Kanseri	300	136,289	240,13735
	Prostat Büyümesi	29	157,4483	112,42191

Çizelge 4.11. İkincil Örneklem Betimsel Bulguları

4.5.2.2. İkincil örneklem yapay sinir ağları sınıflandırma bulguları

İkincil örneklem %91'ü prostat kanseri ve %9'sı prostat büyümesi verilerinden oluşmaktadır. Analiz Python yazılım dilinde veriler notebook çalışma sayfasında sclearn kütüphanesi üzerinde çalışma kodlar bloğu ile yapılmıştır. Veriler %30 test ,%70 eğitim seti olarak ayrılmıştır.

Parametre Uzayı	
Gizli Katman Sayısı	(10,30,10)(20,10),(5,)
Aktivasyon Fonksiyonu	Tanh,Relu
Alpha	(0.001,0.1)
Öğrenim Hızı	Adaptive

Çizelge 4.12. Yapay Sinir Ağlarında Oluşturulan Parametre Uzayı

Oluşturulan sınıflandırma modellerinden en iyi model seçimi selearn kütüphanesi ile optimize edilmiştir. Seçilen en iyi modelin parametreleri Çizelge 4.15’de verilmiştir.

Gizli Katman sayısı	10
Aktivasyon fonksiyonu	Tanh
Alpha	0.001
İterasyon	100

Çizelge 4.13. En İyi Sınıflandırma Modelinin Parametre Uzayı

	Gerçek Pozitif	Gerçek Negatif
Tahmin Pozitif	89	0
Tahmin Negatif	10	0

Çizelge 4.14. En İyi Sınıflandırma Modelinin Hata Matrisi

Doğruluk	0.89899
Kesinlik	0.89899
Duyarlılık	1.0
F1 Score	0.946809
Özgüllük	0.820909
Hasasiyet	0.497297
Cohen Kappa	0.962216
Eğitim Süresi	0.113895
Değer alma süresi	0.00399

Çizelge 4.15. Yapay Sinir Ağlarında Sınıflandırma Sonuç Metrikleri

4.5.2.3. İkincil örneklem destek vektör makineleri sınıflandırma bulguları

Hiperparametre Uzayı	
Ceza Parametresi	(1,10)
Gamma	(0.01,0.001)
Derece	2,3
Çekirdek	Rbf,Poly,Sigmoid,Linear

Çizelge 4.16. DVM Sınıflandırma Hiperparametre Uzayı

Derece	Ceza Parametresi	Gamma	Kernel	Toplam Zaman
2	1	0.01	Rbf	0.0s
2	1	0.01	Poly	13.0s
2	1	0.01	Poly	20.9s
2	1	0.01	Sigmoid	0.0s
2	1	0.01	Sigmoid	0.0s
2	1	0.01	Linear	16.0s
2	1	0.01	Linear	20.0s
2	1	0.01	Linear	6s
2	1	0.001	Rbf	0.0s
2	1	0.001	Rbf	0.0s
2	1	0.001	Rbf	0.0s
2	1	0.001	Poly	0.1s
2	1	0.001	Poly	0.5s
2	1	0.001	Poly	3.0s
2	1	0.001	Sigmoid	0.0s
2	1	0.001	Sigmoid	0.0s
2	1	0.001	Sigmoid	0.0s
2	1	0.001	Sigmoid	0s
2	10	0.01	Rbf	0.0s
2	10	0.01	Poly	16.2s
2	10	0.001	Sigmoid	0.0s
2	10	0.001	Linear	11.3s

Çizelge 4.17. DVM Sınıflandırma Üretilen Modeller

Hiperparametre		Test Doğruluğu	Eğitim Doğruluğu
Ceza Parametresi	1	0.97	0.90
Derece	2		
Gamma	0.01		
Kernel	rbf		

Çizelge 4.18. DVM Sınıflandırma En İyi Model ve Doğruluk Ölçütü

	Gerçek Pozitif	Gerçek Negatif
Tahmin Pozitif	89	0
Tahmin Negatif	10	0

Çizelge 4.19. DVM Sınıflandırma Hata Matrisi

Accuracy	0.89899
Precision	0.89899
Recall	0.898182
F1 Score	0.946809
Specificity	0.918182
Sensitivity	0.332131
Cohen Kappa	0.155763
Eğitim Süresi	0.007779
Score Süresi	0.005185

Çizelge 4.20. DVM Sınıflandırma Model Sonuç Metrikleri

5. SONUÇLAR VE ÖNERİLER

İstatistiksel veri analizinde son yıllarda popüler olarak kullanılan makine öğrenim yöntemlerinden yapay sinir ağları ve destek vektör makineleri diğer klasik istatistiksel yöntemlerden performansı yüksek, hata payı düşük başarılı sonuçlar vermektedir.

Bu çalışmada makine öğrenim yöntemlerinden yapay sinir ağları ve destek vektör makineleri ile prostat spesifik antijeni (PSA), idrar tetkik parametreleri (bld, glu, ket, leu, nit, ph,pro,sg,uro),alkalen fosfataz,kolestrol (ldl) prostat kanseri yada prostat büyüme ön tanısı koymada hekimlerimize etkili bir yol gösterebilmesi için sınıflandırma yapılmıştır. Sınıflandırma sonucunda istatistiksel açıdan başarılı olan sonuçlar uygulama bölümünde verilmiştir. Çalışmanın uygulama kısmında veri sayısı ve tip değişkenliği sebebiyle iki adet veri seti oluşturulmuş ve bu iki adet veri tipi üzerinden sınıflandırma yapılmıştır. Birincil veri setinde psa ve idrar tetkiki parametreleri, ikincil veri setinde ise psa, alkalen fosfataz, kolesterol değerlerine yer verilmiştir. Literatüre göre idrar tetkiki verilerinin ayrı ayrı prostat kanserine etkisi bulunmamaktadır. Fakat hekimler tarafından ilk istenen tetkik ve teşhis için önemli yer almaktadır. Bu sebeple alınan veriler hasta bazlı olmak üzere prostat kanseri ve prostat büyümesi nitelendirilerek ikiye ayrılmaktadır. Birincil veriler ve ikincil veriler literatüre uygun olarak %30 test ,%70 test verisi olarak makineye sunulmuştur.

Çalışmada birincil verilerin YSA sınıflandırılmasında 1374 bireye ait üst tarafta belirtilen biyobelirteçlerden rastgele örnekler seçilip makineye verilerek eğitim, doğrulama ve test yapılmıştır. Sclearn kütüphanesi kullanılarak YSA’da rbf, linear, sigmoid, tanjh, polinomial çekirdek fonksiyonları kullanılarak 100 iterasyonda 48 model üretilmiştir.Üretilen sınıflandırmamodeller arasından sklearn kütüphanesinden params() koduyla en iyi model seçilmiştir.En iyi modelin doğruluğu %65, duyarlılığı %30,özgüllük,%82 olarak bulunmuştur.Birincil verilerin destek vektör makinelerinde 160 adet sınıflandırma modeli üretilmiştir.Bu modellerden en iyi sınıflandırıcı modelin doğruluğu %68, , duyarlılığı %43,özgüllük,%84 olarak bulunmuştur. Parametrik olmayan bu verilerde en iyi sınıflandırma modeli destek vektör makineleri olarak görülmektedir. Destek vektör makinelerinin yapay sinir ağlarına göre daha güçlü ayırma gücü olduğu gözükmemektedir.İkincil verilerde her iki yönteminde doğruluğu çok iyi çıkmıştır. Buda bağımsız değişkenlerin hastalık çeşitleri üzerinde etkisi olduğu düşüncesini

doğrulamaktadır. İkincil örneklem büyüklüğü 329'dur. YSA sınıflandırıcı uygulama sonucunda en iyi sınıflandırma modelinin doğruluğu %89, duyarlılığı %33, Özgüllük %84 çıkmıştır. DVM 'nin doğruluğu %89, duyarlılığı %49, Özgüllük %91 çıkmıştır. Hemen hemen iki yönteminde doğruluğu aynıdır fakat DVM'nin özgüllük ve duyarlılık değeri daha yüksektir. Bu veriler için en iyi sınıflandırıcı DVM diyebiliriz. İkincil verilerde kolesterol değerinin prostat kanseri olan ilişkisi göz ardı edilemez bir gerçektir ki sınıflandırma doğrulukları daha yüksek çıkmıştır. Literatürde Allott'un 2014'de yapmış olduğu çalışmasında prostat kanseri olan 843 hasta seçilmiş ve kolesterol seviyelerine göre gruba ayırmıştır. Trigliserid seviyesi yüksek seyredenlerde kanserin tekrar etme ihtimalini ise % 35 olarak yüksek bulmuştur. Prostat kanserinde yağlanma ve sağlıklı beslenme kriterleri çok önemli bir yer almaktadır.

Literatürde yer alan Djavan ve arkadaşlarının yaptığı çalışmada, Total prostat spesifik antijen (PSA) seviyeleri 2.5 ila 4 ng/mL ve 4 ila 10 ng/mL olan erkeklerde prostat kanserinin erken tespiti için iki yapay sinir ağı (YSA) ileriye dönük tahmin modelleri kurmuşlardır. YSA'nın öngörücü doğruluğunu standart PSA parametrelerinin geleneksel istatistiksel analiz ile karşılaştırma yapılmıştır. Seçilen hastalar serum toplam PSA düzeyi 4 ila 10 ng/mL (n = 974) ve 2.5 ila 4 ng/mL (n = 272)'dir. Her hasta grubu için ayrı bir YSA modeli geliştirilmiştir. Oluşturulan iki karakteristik (ROC) eğrisi (AUC) altındaki alan, 2.5 ila 4 ng/mL ve 4 ila 10 ng/mL ANN modelleri için sırasıyla %87,6 ve %91,3 olmuştur. Kendi çalışmamızdan doğrudan PSA üzerinde yoğunlaşılmamıştır. Ön tetkiklerin değerlendirme hususunda en iyi ön tanı koyabilecek makine öğrenim yöntemi üzerinde durulmuştur. Literatürde spesifik tek biyobelirteç sıklıkla kullanılmaktadır. Bizim çalışmamızın özgüllüğü yeni bilgisayar tabanlı ön tanıların gerçekleştirilmesi için önemli bir yer kapsamaktadır. Çünkü birden fazla biyobelirteçin ele alınması gerekliliğini öne sürmekteyiz.

Üroloji kliniklerine başvuran hastaların klasik prosüdür tetkiklerinin ön tanı için ayırıcı nitelikte olabilmesi adına bilgisayar ve istatistik tabanlı sınıflandırmanın geliştirilmesi gerekmektedir. Çalıştığımız makine öğrenim yöntemlerinden farklı yapıda veriye özgü yeni çalışmalarla geliştirilebilir. DVM'nin yapay sinir ağlarına karşın önemli bir farkı vardır ki oda veriyi çok öğrenme veya az öğrenme gibi sonuçlar vermemeyi sağlar. İlerleyen çalışmalar yapay sinir ağlarında derin öğrenme metodolojisi uygulayarak yeni sınıflandırma ağ yapıları kurulabilir ve DVM perfonması ile karşılaştırılabilir.

Üroloji sađlık alıřanlarına kolaylıklar sunabilmek kanser gibi zor bir hastalıđın erken tanı ile tespit edebilmek iin geliřtirilen sınıflandırma ile bilgisayar tabanlı ön tanı sistemleri kurulması önerilmektedir.



KAYNAKLAR DİZİNİ

Abbasi, A. A., Hussain, L., Awan, I. A., Abbasi, I., Majid, A., Nadeem, M. S. A., & Chaudhary, Q. A. (2020). Detecting prostate cancer using deep learning convolution neural network with transfer learning approach. *Cognitive Neurodynamics*, 14(4), 523-533.

AKBEN S. Batuhan, ALKAN Ahmet, 2012, EEG Verilerine Uygulanan Deneysel Kip Ayrışımı Temelli Kümelemenin Migren Teşhisinde Kullanılması, Elektronik ve Bilgisayar Mühendisliği Sempozyumu, 29 Kasım - 01 Aralık 2012, Bursa.

Akben, S. B., Tuncel, D., & Alkan, A. (2016). Classification of multi-channel EEG signals for migraine detection. *Biomedical Research*, 27(3), 743-748.

AKGÜN Barış, 2016, Apache Spark Tabanlı Destek Vektör Makineleri İle Akan Büyük Veri Sınıflandırma, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi.

Akgün, B. (2016). Apache Spark Tabanlı Destek Vektör Makineleri İle Akan Büyük Veri Sınıflandırma (Doctoral dissertation, Fen Bilimleri Enstitüsü).

AKŞEHİRLİ, Ö. Y., ANKARALI, H., AYDIN, D., & SARAÇLI, Ö. (2013). Tıbbi Tahminde Alternatif Bir Yaklaşım: Destek Vektör Makineleri. *Türkiye Klinikleri Journal of Biostatistics*, 5(1).

AKŞEHİRLİ, Ö. Y., ANKARALI, H., AYDIN, D., & SARAÇLI, Ö. (2013). Tıbbi Tahminde Alternatif Bir Yaklaşım: Destek Vektör Makineleri. *Türkiye Klinikleri Journal of Biostatistics*, 5(1).

Allott, E. H., Howard, L. E., Cooperberg, M. R., Kane, C. J., Aronson, W. J., Terris, M. K., ... & Freedland, S. J. (2014). Serum lipid profile and risk of prostate cancer recurrence: results from the SEARCH database. *Cancer Epidemiology and Prevention Biomarkers*, 23(11), 2349-2356.

Atasoy Nesrin Aydın, Demiröz Ahmet, 2021, Makine Öğrenmesi Algoritmaları Kullanılarak Prostat Kanseri Tümör Oluşumunun İncelenmesi, Avrupa Bilim ve Teknoloji Dergisi Özel Sayı 29, S. 87-92, Aralık 2021.

KAYNAKLAR DİZİNİ (devam)

Atasoy Nesrin Aydın, Demiröz Ahmet, 2021, Makine Öğrenmesi Algoritmaları Kullanılarak Prostat Kanseri Tümör Oluşumunun İncelenmesi, Avrupa Bilim ve Teknoloji Dergisi Özel Sayı 29, S. 87-92, Aralık 2021

ATASOY, N. A., & DEMİRÖZ, A. Makine Öğrenmesi Algoritmaları Kullanılarak Prostat Kanseri Tümör Oluşumunun İncelenmesi. Avrupa Bilim ve Teknoloji Dergisi, (29), 87-92.

AVŞAR Ercan, 2009, Tek-Sınıf Destek Vektör Makineleri Kullanılarak Epileptik Eeg İşaretlerinin Sınıflandırılması, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi .

Avşar, E. (2009). Tek–Sınıf Destek Vektör Makineleri Kullanılarak Epileptik Eeg İşaretlerinin Sınıflandırılması (Doctoral dissertation, Fen Bilimleri Enstitüsü).

Ayhan, S., & ERDOĞMUŞ, Ş. (2014). Kernel function selection for the solution of classification problems via support vector machines. ESKİSEHİR OSMANGAZI UNIVERSİTESİ İIBF DERGİSİ-ESKİSEHİR OSMANGAZI UNIVERSITY JOURNAL OF ECONOMICS AND ADMINISTRATIVE SCIENCES, 9(1).

Aytuğ, O. N. A. N., & Korukoğlu, S. (2016). Makine öğrenmesi yöntemlerinin görüş madenciliğinde kullanılması üzerine bir literatür araştırması. Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, 22(2), 111-122.

Barlow, H., Mao, S., & Khushi, M. (2019). Predicting high-risk prostate cancer using machine learning methods. Data, 4(3), 129.

BAŞER, B. Ö., YANGIN, M., & SARIDAŞ, E. S. (2021). Makine öğrenmesi teknikleriyle diyabet hastalığının sınıflandırılması. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 25(1), 112-120.

BAŞER, B. Ö., YANGIN, M., & SARIDAŞ, E. S. (2021). Makine öğrenmesi teknikleriyle diyabet hastalığının sınıflandırılması. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 25(1), 112-120.

KAYNAKLAR DİZİNİ (devam)

Bibault, J. E., Hancock, S., Buyyounouski, M. K., Bagshaw, H., Leppert, J. T., Liao, J. C., & Xing, L. (2021). Development and Validation of an Interpretable Artificial Intelligence Model to Predict 10-Year Prostate Cancer Mortality. *Cancers*, 13(12), 3064.

Borrelli, P., Larsson, M., Ulén, J., Enqvist, O., Trägårdh, E., Poulsen, M. H., ... & Edenbrandt, L. (2021). Artificial intelligence-based detection of lymph node metastases by PET/CT predicts prostate cancer-specific survival. *Clinical Physiology and Functional Imaging*, 41(1), 62-67.

Bulten, W., Balkenhol, M., Belinga, J. J. A., Brilhante, A., Çakır, A., Egevad, L., ... & Litjens, G. (2021). Artificial intelligence assistance significantly improves Gleason grading of prostate biopsies by pathologists. *Modern Pathology*, 34(3), 660-671.

Carpenter ve Grossberg, (1988). Nöral ağlar Cilt 1, Sayı 1, 1988, Sayfa 17-61

Carpenter ve Grossberg, (1988). Nöral ağlar Cilt 1, Sayı 1, 1988, Sayfa 17-61

Carpenter, G. A., & Grossberg, S. (1993). Normal and amnesic learning, recognition and memory by a neural model of cortico-hippocampal interactions. *Trends in neurosciences*, 16(4), 131-137.

Carpenter, G. A., & Grossberg, S. (1993). Normal and amnesic learning, recognition and memory by a neural model of cortico-hippocampal interactions. *Trends in neurosciences*, 16(4), 131-137.

Castanho, M. D. P., Hernandes, F., De Ré, A. M., Rautenberg, S., & Billis, A. (2013). Fuzzy expert system for predicting pathological stage of prostate cancer. *Expert systems with applications*, 40(2), 466-470.

Che, Y., Shi, X., Shi, Y., Jiang, X., Ai, Q., Shi, Y., ... & Jiang, W. (2019). Exosomes derived from miR-143-overexpressing MSCs inhibit cell migration and invasion in human prostate cancer by downregulating TFF3. *Molecular Therapy-Nucleic Acids*, 18, 232-244.

KAYNAKLAR DİZİNİ (devam)

Chen, S., Huang, V., Xu, X., Livingstone, J., Soares, F., Jeon, J., ... & He, H. H. (2019). Widespread and functional RNA circularization in localized prostate cancer. *Cell*, 176(4), 831-843.

Churilov, L., Bagirov, A., Schwartz, D., Smith, K., & Dally, M. (2005). Data mining with combined use of optimization techniques and self-organizing maps for improving risk grouping rules: application to prostate cancer patients. *Journal of Management Information Systems*, 21(4), 85-100.

Cosma, G., Acampora, G., Brown, D., Rees, R. C., Khan, M., & Pockley, A. G. (2016). Prediction of pathological stage in patients with prostate cancer: a neuro-fuzzy model. *PloS one*, 11(6), e0155856.

Crawford, E. D., Batuello, J. T., Snow, P., Gamito, E. J., McLeod, D. G., Partin, A. W., ... & Brandt, J. (2000). The use of artificial intelligence technology to predict lymph node spread in men with clinically localized prostate carcinoma. *Cancer: Interdisciplinary International Journal of the American Cancer Society*, 88(9), 2105-2109.

Cuocolo, R., Cipullo, M. B., Stanzione, A., Ugga, L., Romeo, V., Radice, L., ... & Imbriaco, M. (2019). Machine learning applications in prostate cancer magnetic resonance imaging. *European radiology experimental*, 3(1), 1-8.

Çakır F. S.,(2019)Yapay Sinir Ağları Matlab Kodları Ve Matlab Toolbox Çözümleri,Atlas Akademik Basım Yayın Dağıtım.

Çakır F. S.,(2019)Yapay Sinir Ağları Matlab Kodları Ve Matlab Toolbox Çözümleri,Atlas Akademik Basım Yayın Dağıtım.

Çomak,(2008) Destek vektör makineleri için yeni bir eğitim yöntemi: Kümeleme k-NN destek vektör makineleri, Uygulamalarla uzmanlık sistemleri, Cilt 35, Sayı 3 , Ekim 2008 , Sayfalar 564-568

Çomak,(2008) Destek vektör makineleri için yeni bir eğitim yöntemi: Kümeleme k-NN destek vektör makineleri, Uygulamalarla uzmanlık sistemleri, Cilt 35, Sayı 3 , Ekim 2008 , Sayfalar 564-568.

KAYNAKLAR DİZİNİ (devam)

Demolli Halil, Ecemiş Alper, Dokuz Ahmet Şakir, Gökçek Murat, 2019, Makine Öğrenmesi Algoritmalarıyla Güneş Enerjisi Tahmini: Niğde İli Örneği, International Turkic World Congress on Science and Engineering 17-18 June 2019, Niğde – Turkey.

Demolli Halil, Ecemiş Alper, Dokuz Ahmet Şakir, Gökçek Murat, 2019, Makine Öğrenmesi Algoritmalarıyla Güneş Enerjisi Tahmini: Niğde İli Örneği, International Turkic World Congress on Science and Engineering 17-18 June 2019, Niğde – Turkey.

Demolli, H., Ecemiş, A., Dokuz, A. Ş., & Gökçek, M. Makine Öğrenmesi Algoritmalarıyla Güneş Enerjisi Tahmini: Niğde İli Örneği.

Demuthve Beale,(2000). Mevsimlik Kar Erimesinin Yapay Sinir Ağları Yöntemi İle Tahmin Edilmesi, S.Ü. Müh.-Mim. Fak. Derg., c.21, s.3-4, 2006

Demuthve Beale,(2000). Mevsimlik Kar Erimesinin Yapay Sinir Ağları Yöntemi İle Tahmin Edilmesi, S.Ü. Müh.-Mim. Fak. Derg., c.21, s.3-4, 2006

Dr. Kosova Buket, Tıbbi Biy. Özel Rukiye, Tıbbi Biy. Aktan Çağdaş, 2011, Prostat kanseri tanısında DNA metilasyonunun yeri var mı? , Ege Üniversitesi Tıp Fakültesi, Tıbbi Biyoloji Anabilim Dalı, İzmir, Haziran 2011 • Sayı 2

Dr. Kosova Buket, Tıbbi Biy. Özel Rukiye, Tıbbi Biy. Aktan Çağdaş, 2011, Prostat kanseri tanısında DNA metilasyonunun yeri var mı? , Ege Üniversitesi Tıp Fakültesi, Tıbbi Biyoloji Anabilim Dalı, İzmir, Haziran 2011 • Sayı 2

Ekin Dr. Rahmi Gökhan, Zorlu Dr. Ferruh, 2013, Türkiye verilerine göre prostat kanseri taranmalı mı? C i l t : 1 2 S a y ı : 2, Tepecik Eğitim ve Araştırma Hastanesi, İzmir

Ekin Dr. Rahmi Gökhan, Zorlu Dr. Ferruh, 2013, Türkiye verilerine göre prostat kanseri taranmalı mı? C i l t : 1 2 S a y ı : 2, Tepecik Eğitim ve Araştırma Hastanesi, İzmir

ELMAS, B., YAKUT, E., & ALKAN, Ö. (2011). İşletmelerin Mali Başarısızlığının Yapay Sinir Ağları ve Lojistik Regresyon Modeli ile Tahmin Edilmesi. Finans Politik ve Ekonomik Yorumlar, (560), 45.

KAYNAKLAR DİZİNİ (devam)

ELMAS, B., YAKUT, E., & ALKAN, Ö. (2011). İşletmelerin Mali Başarısızlığının Yapay Sinir Ağları ve Lojistik Regresyon Modeli ile Tahmin Edilmesi. Finans Politik ve Ekonomik Yorumlar, (560), 45.

ERDAL, Y. M. H. İ., & BARAY, A. (2011). DESTEK VEKTÖR MAKİNELERİ İLE TAHMİNE DAYALI MODELLEME VE BİR UYGULAMA.

ERGUDEN Deniz, 2012, İskenderun Körfezinde Nesli Tehlike Altında Olan Kıkırdaklı Balık Türleri, Su Altı Bilim ve Teknoloji Toplantısı

Ergüden, S. A., & Göksu, M. Z. L. (2012). The fish fauna of the Seyhan dam lake (Adana). Journal of Fisheries Sciences. com, 6(1), 39-52.

ERGÜL, Z. G., & DEMİRTAŞ, N. Prostat kanseri teşhisi için soft expert kümelere dayanan karar verme probleminin bir uygulaması. Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 24(1), 79-90.

EROĞLU Canan, 2014, PC-3 Ve Lncap PROSTAT KANSERİ HÜCRE HATLARINDA FERULİK ASİTİN ETKİSİNİN ARAŞTIRILMASI, YÜKSEK Lisans Tezi, PAMUKKALE Üniversitesi SAĞLIK Bilimleri Enstitüsü

Eroğlu, C., Seçme, M., Bağcı, G., & Dodurga, Y. (2015). Assessment of the anticancer mechanism of ferulic acid via cell cycle and apoptotic pathways in human prostate cancer cell lines. Tumor Biology, 36(12), 9437-9446.

Fausett, L. V., & Elwasif, W. (1994, June). Predicting performance from test scores using backpropagation and counterpropagation. In Proceedings of 1994 IEEE International Conference on Neural Networks (ICNN'94) (Vol. 5, pp. 3398-3402). IEEE.

Fausett, L. V., & Elwasif, W. (1994, June). Predicting performance from test scores using backpropagation and counterpropagation. In Proceedings of 1994 IEEE International Conference on Neural Networks (ICNN'94) (Vol. 5, pp. 3398-3402). IEEE.

KAYNAKLAR DİZİNİ (devam)

FILIZ Enes, KARABOGA Hasan Aykut, AKOGUL Serkan, 2017, Bıst-50 Endeksi Değişim Değerlerinin Sınıflandırılmasında Makine Öğrenmesi Yöntemleri Ve Yapay Sinir Ağları Kullanımı, Ç.Ü. Sosyal Bilimler Enstitüsü Dergisi, Cilt 26, Sayı 1, 2017, Sayfa 231-241

Filiz, E., Karaboğa, H. A., & Akoğul, S. (2017). BIST-50 ENDEKSİ DEĞİŞİM DEĞERLERİNİN SINIFLANDIRILMASINDA MAKİNE ÖĞRENMESİ YÖNTEMLERİ VE YAPAY SİNİR AĞLARI KULLANIMI. Çukurova Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 26(1), 231-241.

Filiz, E., Karaboğa, H. A., & Akoğul, S. (2017). BIST-50 ENDEKSİ DEĞİŞİM DEĞERLERİNİN SINIFLANDIRILMASINDA MAKİNE ÖĞRENMESİ YÖNTEMLERİ VE YAPAY SİNİR AĞLARI KULLANIMI. Çukurova Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 26(1), 231-241.

Garraway WM, Collins CJ, Lee RJ. High prevalence of benign prostatic hypertrophy in the community. Lancet 1991; 338-469-71.

Garraway WM, Collins CJ, Lee RJ. High prevalence of benign prostatic hypertrophy in the community. Lancet 1991; 338-469-71.

Garraway WM, Collins CJ, Lee RJ. High prevalence of benign prostatic hypertrophy in the community. Lancet 1991; 338-469-71.

Gour,(2019). Quantum resource theories, Eric Chitambar and Gilad Gour, Rev. Mod. Phys. 91, 025001 – Published 4 April 2019

Gour,(2019). Quantum resource theories, Eric Chitambar and Gilad Gour, Rev. Mod. Phys. 91, 025001 – Published 4 April 2019

Gunn,(1998). Support Vector Machines for Classification and Regression, Universty of Southampton

Gunn,(1998). Support Vector Machines for Classification and Regression, Universty of Southampton.

KAYNAKLAR DİZİNİ (devam)

Gurney, K. (2018). An introduction to neural networks. CRC press.

Gurney, K. (2018). An introduction to neural networks. CRC press.

GÜLDOĞAN Emek, 2017, Çeşitli Çekirdek Fonksiyonları İle Oluşturulan Destek Vektör Makinesi Modellerinin Performanslarının İncelenmesi: Bir Klinik Uygulama, Doktora Tezi, İnönü Üniversitesi Ve Mersin Üniversitesi Biyoistatistik Ve Tıp Bilişimi Anabilim Dalı Ortak Doktora Programı

Güldoğan, E. (2017). Çeşitli çekirdek fonksiyonları ile oluşturulan destek vektör makinesi modellerinin performanslarının incelenmesi: Bir klinik uygulama.

Güldoğan, E. (2017). Çeşitli çekirdek fonksiyonları ile oluşturulan destek vektör makinesi modellerinin performanslarının incelenmesi: Bir klinik uygulama.

GÜRSOY Mutlu, BALABAN Mehmet Erdal, 2014, Hisse Senedi Getirilerindeki Volatilitenin Tahminlenmesinde Destek Vektör Makinelerine Dayalı Garch Modellerinin Kullanımı, Kafkas Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Dergisi Cilt 5, Sayı 8

Gürsoy, M., & Balaban, M. (2014). Hisse Senedi Getirilerindeki Volatilitenin Tahminlenmesinde Destek Vektör Makinelerine Dayalı Garch Modellerinin Kullanımı. Kafkas Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 5(8), 167-186.

Gürsoy, M., & Balaban, M. (2014). Hisse Senedi Getirilerindeki Volatilitenin Tahminlenmesinde Destek Vektör Makinelerine Dayalı Garch Modellerinin Kullanımı. Kafkas Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 5(8), 167-186.

GÜZEL ERGÜL Zehra, DEMİRTAŞ Naime, 2022, Prostat kanseri teşhisi için soft expert kümelere dayanan karar verme probleminin bir uygulaması, BAUN Fen Bil. Enst. Dergisi, 24(1), 79-90

Hamzaçebi C. (2011) Yapay Sinir Ağları Tahmin Amaçlı Kullanımı Matlab ve Neurosolutions Uygulamalı, Ekin Basım Yayın Dağıtım.

Hamzaçebi C. (2011) Yapay Sinir Ağları Tahmin Amaçlı Kullanımı Matlab ve Neurosolutions Uygulamalı, Ekin Basım Yayın Dağıtım.

KAYNAKLAR DİZİNİ (devam)

Hamzaçebi C.,(2011) Yapay Sinir Ağları Tahmin Amaçlı Kullanımı Matlab ve Neurosolutions Uygulamalı ,Ekin Basım Yayın Dağıtım.

Hamzaçebi C.,(2011) Yapay Sinir Ağları Tahmin Amaçlı Kullanımı Matlab ve Neurosolutions Uygulamalı ,Ekin Basım Yayın Dağıtım.

Harmon, S. A., Gesztes, W., Young, D., Mehralivand, S., McKinney, Y., Sanford, T., ... & Turkbey, B. (2021). Prognostic features of biochemical recurrence of prostate cancer following radical prostatectomy based on multiparametric mri and immunohistochemistry analysis of MRI-guided biopsy specimens. Radiology.

Haykin ,S., (1999),”Neurol Networks- A Comprehensive Foundation”,Prentice Hall,2.Edition ,New Jersey.

Haykin ,S., (1999),”Neurol Networks- A Comprehensive Foundation”,Prentice Hall,2.Edition ,New Jersey.

Haykin ,S., (1999),”Neurol Networks- A Comprehensive Foundation”,Prentice Hall,2.Edition ,New Jersey.

Haykin ,S., (1999),”Neurol Networks- A Comprehensive Foundation”,Prentice Hall,2.Edition ,New Jersey.

Hebb,D.O., (1949)”The Organization of Behavior :A Neuropsychological Theory”,New York:Wiley and Sons.

Hebb,D.O., (1949)”The Organization of Behavior :A Neuropsychological Theory”,New York:Wiley and Sons.

Hebb,D.O., (1949)”The Organization of Behavior :A Neuropsychological Theory”,New York:Wiley and Sons.

Hüseyin, İ. N. C. E., & İMAMOĞLU, S. Z. (2016). Destek vektör regresyon ve ikiz destek vektör regresyon yöntemi ile tedarikçi seçimi. Doğuş Üniversitesi Dergisi, 17(2), 241-253.

KAYNAKLAR DİZİNİ (devam)

İLHANLI Nevruz, 2019, Prostat Kanseri Riskinin Bulanık Mantık Yaklaşımı İle Belirlenmesi, Yüksek Lisans Tezi, Akdeniz Üniversitesi Sağlık Bilimleri Enstitüsü Biyoistatistik Ve Tıbbi Bilişim Anabilim Dalı

İLHANLI Nevruz, 2019, Prostat Kanseri Riskinin Bulanık Mantık Yaklaşımı İle Belirlenmesi, Yüksek Lisans Tezi, Akdeniz Üniversitesi Sağlık Bilimleri Enstitüsü Biyoistatistik Ve Tıbbi Bilişim Anabilim Dalı

İlhanlı, N. (2019). Prostat kanseri riskinin bulanık mantık yaklaşımı ile belirlenmesi.

İNCE Hüseyin, İMAMOĞLU Salih Zeki, 2016, Destek Vektör Regresyon Ve İkiz Destek Vektör Regresyon Yöntemi İle Tedarikçi Seçimi, Doğu Üniversitesi Dergisi, 17 (2) 2016, 241-253

KARAGÜL Kenan, 2014, İstanbul Menkul Kıymetler Borsası'nda İşlem Gören Firmaların Destek Vektör Makineleri Kullanılarak Sınıflandırılması, Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, Cilt 20, Sayı 5, 2014, Sayfalar 174-178.

Karagül, K. (2014). İstanbul Menkul Kıymetler Borsası'nda İşlem Gören Firmaların Destek Vektör Makineleri Kullanılarak Sınıflandırılması. Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, 20(5), 174-178.

Karagül, K. (2014). İstanbul Menkul Kıymetler Borsası'nda İşlem Gören Firmaların Destek Vektör Makineleri Kullanılarak Sınıflandırılması. Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, 20(5), 174-178.

Kardelen Kurtdere, A. (2022). İnsan prostat kanseri hücre hattı pc-3'te oxaplatin ve stat3 inhibitörü piceatannol kombinasyonunun tgf- β sinyal yolağı aracılı sitotoksik etkisi (Master's thesis, Trakya Üniversitesi Sağlık Bilimleri Enstitüsü).

KARTAL Hasan Basri, 2012, Envanter Sınıflandırmada Yapay Öğrenme Yöntemlerinin Kullanımı Ve Destek Vektör Makineleri İle Bir Uygulama, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü.

KAYNAKLAR DİZİNİ (devam)

KARTAL, C. (2020). Destek Vektör Makineleri ile Borsa Endekslerinin Tahmini. Itobiad: Journal of The Human & Social Science Researches, 9(2).

KARTAL, C. (2020). Destek Vektör Makineleri ile Borsa Endekslerinin Tahmini. Itobiad: Journal of The Human & Social Science Researches, 9(2).

Kartal, H. B. (2012). Envanter sınıflandırmada yapay öğrenme yöntemlerinin kullanımı ve destek vektör makineleri ile bir uygulama (Doctoral dissertation, Fen Bilimleri Enstitüsü).

Kartal, H. B. (2012). Envanter sınıflandırmada yapay öğrenme yöntemlerinin kullanımı ve destek vektör makineleri ile bir uygulama (Doctoral dissertation, Fen Bilimleri Enstitüsü).

KAVCIOĞLU Şahap, 2019, Kurumsal Kredi Skorlamasında Klasik Yöntemlerle Yapay Sinir Ağı Karşılaştırması, İstanbul İktisat Dergisi 69, 2019/2, s. 207-245

Kavcioğlu, Ş. (2019). Kurumsal Kredi Skorlamasında Klasik Yöntemlerle Yapay Sinir Ağı Karşılaştırması. İstanbul İktisat Dergisi, 69(2), 207-246.

KAYA Mehmet Onur, 2010, Prostat Spesifik Antijeni (Psa)'Nın Değişik Yapay Sinir Ağı Modelleri İle Tahmini, Yüksek Lisans Tezi, Fırat Üniversitesi

KAYA Mehmet Onur, ÇOLAK Cemil, ÖZDEMİR Enver, 2013, Prostat Spesifik Antijeni Yardımı ile Prostat Kanserinin Değişik Yapay Sinir Ağı Modelleri ile Tahmini, İnönü Üniversitesi Sağlık Bilimleri Dergisi 2013; 1: 19-22.

Kaya, Ç., & Yıldız, O. (2014). Makine Öğrenmesi Teknikleriyle Saldırı Tespiti: Karşılaştırmalı Analiz. Marmara University Journal of Science, 26(3).

Kaya, M. C., Yasin, B. E. Z., Demir, A., Bulut, M., Topçuoğlu, V., Kuşçu, M. K., & Türkeri, N. L. (2013). Prostat kanseri hastalarında hastalık evrelerine göre anksiyete, depresyon, cinsel işlev bozukluğu ve yaşam kalitesi. Journal of Mood Disorders, 3(1), 23-7.

KAYNAKLAR DİZİNİ (devam)

Kaya, M. O., Çolak, C., & Özdemir, E. (2013). Prostat spesifik antijeni yardımı ile prostat kanserinin değişik yapay sinir ağı modelleri ile tahmini.

Kecman (2001), Buhar sıkıştırılmalı sıvı soğutucuların dinamik modellemesine yeni yaklaşım: yapay sinir ağları, Uygulamalı Isı Mühendisliği, Cilt 21, Sayı 9, Haziran 2001 , Sayfa 941-953.

Kecman, V. (2001). Learning and soft computing: support vector machines, neural networks, and fuzzy logic models. MIT press.

KENGER Murat Deniz, Banka Personel Seçiminin Çok Kriterli Karar Verme Yöntemlerinden Entropi Temelli Maut, Aras Ve Gri İlişkisel Analiz Yöntemleri İle Değerlendirilmesi, Adnan Menderes Üniversitesi, Sosyal Bilimler Enstitüsü Dergisi, Cilt: 4, Sayı: 4 (Sf. 152-170)

KENGER, M. D., & Organ, A. (2017). Banka personel seçiminin çok kriterli karar verme yöntemlerinden entropi temelli aras yöntemi ile değerlendirilmesi. Adnan Menderes Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 4(4), 152-170.

KIVRAK Mehmet, 2021, Sınıflandırma Problemlerinde Topluluk Öğrenme Yöntemlerinin İncelenmesi Ve Küçük Hücreli Dışı Akciğer Kanseri Verileri Üzerine Bir Uygulaması, Biyoistatistik Ve Tıp Bilişimi Anabilim Dalı Doktora Tezi, İnönü Üniversitesi Sağlık Bilimleri Enstitüsü

Kıvrak, M. (2020). Sınıflandırma problemlerinde topluluk öğrenme yöntemlerinin incelenmesi ve küçük hücreli dışı akciğer kanseri verileri üzerine bir uygulaması.

Kim, M. Y., Shin, H., Moon, H. W., Park, Y. H., Park, J., & Lee, J. Y. (2021). Urinary exosomal microRNA profiling in intermediate-risk prostate cancer. Scientific Reports, 11(1), 1-7.

KÖSE Utku, 2019, Zeki optimizasyon tabanlı destek vektör makineleri ile diyabet teşhisi, Politeknik Dergisi; 22(3) :557-566.

KAYNAKLAR DİZİNİ (devam)

KURTDERE Ayşe Kardelen, 2022, İnsan Prostat Kanseri Hücre Hattı Pc-3'te Oxalıplatın Ve Stat3 İnhibitörü Pıceatannol Kombinasyonunun Tgf-B Sinyal Yolağı Aracılı Sitotoksik Etkisi, Yüksek Lisans Tezi, Trakya Üniversitesi Sağlık Bilimleri Enstitüsü Tıbbi Biyoloji Anabilim Dalı

KUZEY Cemil, 2012, Veri Madenciliğinde Destek Vektör Makinaları ve Karar Ağaçları Yöntemlerini Kullanarak Bilgi Çalışanlarının Kurum Performansı Üzerine Etkisinin Ölçülmesi ve Bir Uygulama, Doktora Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı Sayısal Yöntemler Bilim Dalı

Kuzey, C. (2012). Veri madenciliğinde destek vektör makinaları ve karar ağaçları yöntemlerini kullanarak bilgi çalışanlarının kurum performansı üzerine etkisinin ölçülmesi ve bir uygulama. Yayınlanmamış Doktora Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.

Kuzey, C. (2012). Veri madenciliğinde destek vektör makinaları ve karar ağaçları yöntemlerini kullanarak bilgi çalışanlarının kurum performansı üzerine etkisinin ölçülmesi ve bir uygulama. Yayınlanmamış Doktora Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.

Küçüksille, E. U., & Ateş, N. (2013). Destek Vektör Makineleri ile Yaramaz Elektronik Postaların Filtrelenmesi. Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi, 6(1).

Küçüksille, E. U., & Ateş, N. (2013). Destek Vektör Makineleri ile Yaramaz Elektronik Postaların Filtrelenmesi. Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi, 6(1).

Li, S., Kwok, J. T., Zhu, H., & Wang, Y. (2003). Texture classification using the support vector machines. Pattern recognition, 36(12), 2883-289

Li, S., Kwok, J. T., Zhu, H., & Wang, Y. (2003). Texture classification using the support vector machines. Pattern recognition, 36(12), 2883-2893.

KAYNAKLAR DİZİNİ (devam)

Marginean, F., Arvidsson, I., Simoulis, A., Overgaard, N. C., Åström, K., Heyden, A., ... & Krzyzanowska, A. (2021). An artificial intelligence-based support tool for automation and standardisation of Gleason grading in prostate biopsies. *European Urology Focus*, 7(5), 995-1001.

MERAL Gizem, SARAÇLI Sinan, 2020, Destek Vektör Makineleri ve Türkiye’deki Enerji Santrallerinde Doğal Gaz Tüketimi Üzerine Bir Uygulama, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi Cilt 24, Sayı 2, 411-418

MERAL, G., & SARAÇLI, S. (2020). Destek Vektör Makineleri ve Türkiye’deki Enerji Santrallerinde Doğal Gaz Tüketimi Üzerine Bir Uygulama. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 24(2), 411-418.

NAMLI Özge Hüsniye, 2017, Makine Öğrenmesi Algoritmaları Kullanarak Gişe Hasılatının Tahmini, Yönetim Bilişim Sistemleri Dergisi, Cilt:3, Sayı:2, Sayfa:130-143

NAMLI, E., & Murat, S. (2019). Müşteri Odaklı Pazarlama Stratejileri için Veri Madenciliği Teknikleri Kapsamında Perakende Sektöründe Kümeleme Analizi Uygulaması. *Gümüşhane Üniversitesi Sosyal Bilimler Enstitüsü Elektronik Dergisi*, 10, 317-327.

NAMLI, Ö. H., & ÖZCAN, T. (2017). MAKİNE ÖĞRENMESİ ALGORİTMALARI KULLANARAK GİŞE HASILATININ TAHMİNİ. *Yönetim Bilişim Sistemleri Dergisi*, 3(2), 130-143.

Nelson, C. R., Ekberg, J., & Fridell, K. (2020). Prostate cancer detection in screening using magnetic resonance imaging and artificial intelligence. *The Open Artificial Intelligence Journal*, 6(1).

Nitta, S., Tsutsumi, M., Sakka, S., Endo, T., Hashimoto, K., Hasegawa, M., ... & Nishiyama, H. (2019). Machine learning methods can more efficiently predict prostate cancer compared with prostate-specific antigen density and prostate-specific antigen velocity. *Prostate international*, 7(3), 114-118.

KAYNAKLAR DİZİNİ (devam)

Nitze, I., Schulthess, U., & Asche, H. (2012). Comparison of machine learning algorithms random forest, artificial neural network and support vector machine to maximum likelihood for supervised crop type classification. Proceedings of the 4th GEOBIA, Rio de Janeiro, Brazil, 79, 3540.

Nygren, K. (2004). Stock prediction—a neural network approach. Royal Institute of Technology, 1-34.

Nygren, K. (2004). Stock prediction—a neural network approach. Royal Institute of Technology, 1-34.

Oelke M, Alivizitos G, Emberton M, Gravas S, Madersbacher S, Michel M, Nording J, Rioja Sanz C, de la Rosette J. Benign prostatic hyperplasia in EAU Guidelines pocket edition 3. Arnhem, EAU, 2005; 4-11.

Oelke M, Alivizitos G, Emberton M, Gravas S, Madersbacher S, Michel M, Nording J, Rioja Sanz C, de la Rosette J. Benign prostatic hyperplasia in EAU Guidelines pocket edition 3. Arnhem, EAU, 2005; 4-11.

Oelke M, Alivizitos G, Emberton M, Gravas S, Madersbacher S, Michel M, Nording J, Rioja Sanz C, de la Rosette J. Benign prostatic hyperplasia in EAU Guidelines pocket edition 3. Arnhem, EAU, 2005; 4-11.

ONAN Aytuğ, KORUKOĞLU Serdar, 2016, Makine öğrenmesi yöntemlerinin görüş madenciliğinde kullanılması üzerine bir literatür araştırması, Pamukkale Univ Muh Bilim Derg, 22(2), 111-122

Onan, A., & Bayar, C. (2017). Türkçe Twitter mesajlarında gizli dirichlet tahsisine dayalı duygu analizi. Akademik Bilişim, 8(10).

Onay, F. K., & Köse, C. (2019, April). Power Spectral Density Analysis in Alfa, Beta and Gamma Frequency Bands for Classification of Motor EEG Signals. In 2019 27th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.

Onen, I. H., Konac, E., Eroglu, M., Guneri, C., Biri, H., & Ekmekci, A. (2008). No association between polymorphism in the vascular endothelial growth factor gene at position- 460 and sporadic prostate cancer in the Turkish population. *Molecular biology reports*, 35(1), 17-22.

ÖNEN Cemile İlknur, 2021, Yaygın Anksiyete Semptomlarının Yordanmasında Üstbiliş, Bilinçli Farkındalık Ve Psikolojik Esnekliğin Rolü, Yüksek Lisans Tezi, İstanbul Kent Üniversitesi Lisansüstü Eğitim Enstitüsü

Özgür Atilla, Erdem Hamit, 2012, Saldırı Tespit Sistemlerinde Kullanılan Kolay Erişilen Makine Öğrenme Algoritmalarının Karşılaştırılması, *Bilişim Teknolojileri Dergisi*, Cilt: 5, Sayı: 2, Mayıs 2012

Özgür, A., & Erdem, H. (2012). Saldırı Tespit Sistemlerinde Kullanılan Kolay Erişilen Makine Öğrenme Algoritmalarının Karşılaştırılması. *Bilişim Teknolojileri Dergisi*, 5(2), 41-48.

Özgür, A., & Erdem, H. (2012). Saldırı Tespit Sistemlerinde Kullanılan Kolay Erişilen Makine Öğrenme Algoritmalarının Karşılaştırılması. *Bilişim Teknolojileri Dergisi*, 5(2), 41-48.

ÖZLÜER BAŞER Bilge, YANGIN Metin, SARIDAŞ E. Selin, 2021, Makine Öğrenmesi Teknikleriyle Diyabet Hastalığının Sınıflandırılması, Volume 25, Issue 1, 112 - 120, 20.04.2021

Öztemel, E. (2003). *Yapay sinir ağıları*. PapatyaYayincilik, İstanbul.

Öztemel,(2012). Kariyer Kararsızlığı ile Mesleki Karar Verme Öz Yetkinlik ve Kontrol Odağı Arasındaki İlişkiler, *GEFAD / GUJGEF* 32 (2): 459-477 (2012)

Perincheri, S., Levi, A. W., Celli, R., Gershkovich, P., Rimm, D., Morrow, J. S., ... & Sinard, J. (2021). An independent assessment of an artificial intelligence system for prostate cancer detection shows strong diagnostic accuracy. *Modern Pathology*, 34(8), 1588-1595.

Raciti, P., Sue, J., Ceballos, R., Godrich, R., Kunz, J. D., Kapur, S., ... & Fuchs, T. J. (2020). Novel artificial intelligence system increases the detection of prostate cancer in whole slide images of core needle biopsies. *Modern Pathology*, 33(10), 2058-2066.

KAYNAKLAR DİZİNİ (devam)

Rajesakaran,(2012) Serbest Radikal Biyoloji ve Tıp, Cilt 52, Sayı 2 , 15 Ocak 2012 , Sayfa 366-376

Rajesakaran,(2012) Serbest Radikal Biyoloji ve Tıp, Cilt 52, Sayı 2 , 15 Ocak 2012 , Sayfa 366-376

Regnier-Coudert, O., McCall, J., Lothian, R., Lam, T., McClinton, S., & N'Dow, J. (2012). Machine learning for improved pathological staging of prostate cancer: a performance comparison on a range of classifiers. *Artificial intelligence in medicine*, 55(1), 25-35.

Saygılı,Y.,(2008),”İstatistiksel Yöntemlerle Yapay Sinir Ağları Uygulamalarının Karşılaştırılması: Milli Savunma Bakanlığı Bütçesinin Öngörülmesi”, Kara Harp Okulu Savunma Bilimleri Enstitüsü,Ankara.

Saygılı,Y.,(2008),”İstatistiksel Yöntemlerle Yapay Sinir Ağları Uygulamalarının Karşılaştırılması: Milli Savunma Bakanlığı Bütçesinin Öngörülmesi”, Kara Harp Okulu Savunma Bilimleri Enstitüsü,Ankara.

Saygılı,Y.,(2008),”İstatistiksel Yöntemlerle Yapay Sinir Ağları Uygulamalarının Karşılaştırılması: Milli Savunma Bakanlığı Bütçesinin Öngörülmesi”, Kara Harp Okulu Savunma Bilimleri Enstitüsü,Ankara.

Sensu, S., Erdogan, N., & Gurbuz, Y. S. (2020). Patolojide dijital çağ ve yapay Zekâ: temel bilgiler.

Shah, M., Naik, N., Somani, B. K., & Hameed, B. Z. (2020). Artificial intelligence (AI) in urology-Current use and future directions: An iTRUE study. *Turkish Journal of Urology*, 46(Suppl 1), S27.

Ström, P., Kartasalo, K., Olsson, H., Solorzano, L., Delahunt, B., Berney, D. M., ve Eklund, M. (2019). Pathologist-level grading of prostate biopsies with artificial intelligence. *arXiv preprint arXiv:1907.01368*.

KAYNAKLAR DİZİNİ (devam)

Ström, P., Kartasalo, K., Olsson, H., Solorzano, L., Delahunt, B., Berney, D. M., ... & Eklund, M. (2020). Artificial intelligence for diagnosis and grading of prostate cancer in biopsies: a population-based, diagnostic study. *The Lancet Oncology*, 21(2), 222-232.

Ström, P., Kartasalo, K., Olsson, H., Solorzano, L., Delahunt, B., Berney, D. M., ... & Eklund, M. (2020). Artificial intelligence for diagnosis and grading of prostate cancer in biopsies: a population-based, diagnostic study. *The Lancet Oncology*, 21(2), 222-232.

Ström, P., Kartasalo, K., Olsson, H., Solorzano, L., Delahunt, B., Berney, D. M., ve Eklund, M. (2019). Pathologist-level grading of prostate biopsies with artificial intelligence. *arXiv preprint arXiv:1907.01368*.

TAŞ Engin, 2018, Bilgi Erişimi için Eşli bir Sıralama Algoritması, BEÜ Fen Bilimleri Dergisi 7 (2), 399-408

TAŞ Engin, 2018, Bilgi Erişimi için Eşli bir Sıralama Algoritması, BEÜ Fen Bilimleri Dergisi 7 (2), 399-408

Taş, E. (2017). Gen Örneklerinin Eşli Destek Vektör Makinesi ile Sınıflandırılması. *Alphanumeric Journal*, 5(2), 283-292.

Tătaru, O. S., Vartolomei, M. D., Rassweiler, J. J., Virgil, O., Lucarelli, G., Porpiglia, F., ... & Ferro, M. (2021). Artificial Intelligence and Machine Learning in Prostate Cancer Patient Management—Current Trends and Future Perspectives. *Diagnostics*, 11(2), 354.

Tirumala, S. S., & Narayanan, A. (2019). Classification and diagnostic prediction of prostate cancer using gene expression and artificial neural networks. *Neural Computing and Applications*, 31(11), 7539-7548.

Tirumala, S. S., & Narayanan, A. (2019). Classification and diagnostic prediction of prostate cancer using gene expression and artificial neural networks. *Neural Computing and Applications*, 31(11), 7539-7548.

KAYNAKLAR DİZİNİ (devam)

Twilt, J. J., van Leeuwen, K. G., Huisman, H. J., Fütterer, J. J., & de Rooij, M. (2021). Artificial intelligence based algorithms for prostate cancer classification and detection on magnetic resonance imaging: a narrative review. *Diagnostics*, 11(6), 959.

Uğur,A., ve Kınacı, A.C. (2006).Yapay zeka teknikleri ve yapay sinir ağları kullanılarak web sayfalarının sınıflandırılması.XI. Türkiye’de İnternet Konferansı (inet-tr’06),Ankara,1-4

Uğur,A., ve Kınacı, A.C. (2006).Yapay zeka teknikleri ve yapay sinir ağları kullanılarak web sayfalarının sınıflandırılması.XI. Türkiye’de İnternet Konferansı (inet-tr’06),Ankara,1-4

Uğur,A., ve Kınacı, A.C. (2006).Yapay zeka teknikleri ve yapay sinir ağları kullanılarak web sayfalarının sınıflandırılması.XI. Türkiye’de İnternet Konferansı (inet-tr’06),Ankara,1-4.

Utku, K. Ö. S. E. (2019). Zeki optimizasyon tabanlı destek vektör makineleri ile diyabet teşhisi. *Politeknik Dergisi*, 22(3), 557-566.

Van Booven, D. J., Kuchakulla, M., Pai, R., Frech, F. S., Ramasahayam, R., Reddy, P., ... & Arora, H. (2021). A systematic review of artificial intelligence in prostate cancer. *Research and reports in urology*, 13, 31.

Vapnik, (1995), Support-Vector Networks, *Machine Learning*, 20, 273-297 (1995)

Vapnik, (1995), Support-Vector Networks, *Machine Learning*, 20, 273-297 (1995)

Vapnik,(1992). Optimum marj sınıflandırıcıları için bir eğitim algoritması, COLT '92: Hesaplamalı öğrenme teorisi üzerine beşinci yıllık çalıştayın bildirileri Temmuz 1992 Sayfa 144–152

Vapnik,(1992). Optimum marj sınıflandırıcıları için bir eğitim algoritması, COLT '92: Hesaplamalı öğrenme teorisi üzerine beşinci yıllık çalıştayın bildirileri Temmuz 1992 Sayfa 144–152.

KAYNAKLAR DİZİNİ (devam)

Vogl vd.1988). Algılanan Örgütsel Desteğin Örgütsel Vatandaşlık Davranışlarına Etkisinde Örgütsel Stresin Aracılık Rolü: Beş Yıldızlı Otel İşletmelerinde Bir Araştırma, Uluslararası Alanya İşletme Fakültesi Dergisi, Yıl:2015, C:7, S:2, s. 29-41

Vogl vd.1988). Algılanan Örgütsel Desteğin Örgütsel Vatandaşlık Davranışlarına Etkisinde Örgütsel Stresin Aracılık Rolü: Beş Yıldızlı Otel İşletmelerinde Bir Araştırma, Uluslararası Alanya İşletme Fakültesi Dergisi, Yıl:2015, C:7, S:2, s. 29-41.

Wildeboer, R. R., van Sloun, R. J., Huang, P., Wijkstra, H., & Misch, M. (2019). 3-D multi-parametric contrast-enhanced ultrasound for the prediction of prostate cancer. *Ultrasound in medicine & biology*, 45(10), 2713-2724.

Wulczyn, E., Nagpal, K., Symonds, M., Moran, M., Plass, M., Reih, R., ... & Mermel, C. H. (2021). Predicting prostate cancer specific-mortality with artificial intelligence-based Gleason grading. *Communications Medicine*, 1(1), 1-8.

Yük. Müh. ERDAL Halil İbrahim, 2011, Destek Vektör Makineleri İle Tahmine Dayalı Modelleme Ve Bir Uygulama, Doktora Tezi, İstanbul Üniversitesi Fen Bilimleri Enstitüsü

Župan, D. (2014). Karcinom penisa (Doctoral dissertation, University of Zagreb. School of Medicine. Department of Urology).

EK AÇIKLAMALAR

Ek Açıklama-A: Etik Kurul İzni

EK AÇIKLAMA: ETİK KURUL ONAY ÜST YAZISI ve KARAR FORMU

101



T.C.
ESKİŞEHİR OSMANGAZİ ÜNİVERSİTESİ
Girişimsel Olmayan Klinik Araştırmalar Etik Kurul Başkanlığı

Sayı : E-25403353-050.99-248891

12.11.2021

Konu : 2021 - 308 Karar

Sayın Doç. Dr. Fatih ÇEMREK
Fen Edebiyat Fakültesi
İstatistik Bölümü

Karar Tarihi: 26.10.2021

Karar Sayısı: 14

Etik Kurulların görev tanımları göz önüne alındığında, Eskişehir Osmangazi Üniversitesi İstatistik Bölümü Uygulamalı İstatistik Anabilim Dalı Doç.Dr.Fatih ÇEMREK'in sorumluluğunda yürütülecek olan **"Prostat Kanseri Yapay Zeka ile Ön Tanısı"** başlıklı araştırmanın/çalışmanın gerçekleştirilmesinde etik ve bilimsel açıdan sakınca bulunmadığına karar verilmiştir.

Bilgilerinizi ve gereğini saygı ile rica ederim.

Ek: e-imzalı Etik Kurul Kararı

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Belge Doğrulama Kodu : vfk12gxN142

Belge Doğrulama Adresi : <https://www.turkiye.gov.tr/esogu-ebys>

Adres : Meşelik Kampüsü 26040 Odunpazarı
Telefon : 0222 2393750 Faks: 0222 2291418
İnternet Adresi : www.ogu.edu.tr
KEP adresi : esk.osmangaziunirek@hs01.kep.tr

