



TÜRKİYE CUMHURİYETİ
KARADENİZ TEKNİK ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

BİYOİSTATİSTİK VE TIP BİLİŞİMİ ANABİLİM DALI

**DERİN ÖĞRENME YAKLAŞIMI İLE SİGARA
BIRAKMA TEDAVİSİNİN BELİRLENMESİ
İÇİN KARAR DESTEK SİSTEMİNİN
GELİŞTİRİLMESİ**

Mehmet Erşan KALAYCI

YÜKSEK LİSANS TEZİ

Prof. Dr. Kemal TURHAN

TRABZON-2021



TÜRKİYE CUMHURİYETİ
KARADENİZ TEKNİK ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

BİYOİSTATİSTİK VE TIP BİLİŞİMİ ANABİLİM DALI

**DERİN ÖĞRENME YAKLAŞIMI İLE SİGARA
BIRAKMA TEDAVİSİNİN BELİRLENMESİ
İÇİN KARAR DESTEK SİSTEMİNİN
GELİŞTİRİLMESİ**

Mehmet Erşan KALAYCI

YÜKSEK LİSANS TEZİ

Prof. Dr. Kemal TURHAN

TRABZON-2021

ONAY

Karadeniz Teknik Üniversitesi Sağlık Bilimleri Enstitüsü Biyoistatistik ve Tıp Bilişimi Anabilim Dalı Tezli Yüksek Lisans Programı öğrencisi Mehmet Erşan KALAYCI'nın hazırladığı “Derin Öğrenme Yaklaşımı ile Sigara Bırakma Tedavisinin Belirlenmesi için Karar Destek Sisteminin Geliştirilmesi” başlıklı çalışma Yüksek Lisans Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 28.12.2021

Sağlık Bilimleri Enstitüsü'ne/...../20..... tarihinde teslim edilen bu tez Enstitü Yönetim Kurulu'nun/...../20..... tarih ve sayılı kararıyla onaylanmıştır.

Prof. Dr. Ersan KALAY
Enstitü Müdürü

BEYAN

Bu tez çalışmasının Karadeniz Teknik Üniversitesi Sağlık Bilimleri Enstitüsü Tez Hazırlama ve Yazım Kılavuzu standartlarına uygun olarak hazırlanarak yazıldığını, tezin akademik ve etik kurallara bağlı kalınarak gerçekleştirilmiş özgün bir bilimsel araştırma eserim olduğunu, tezde yer alan ve bu tez çalışmasıyla elde edilmeyen tüm bilgi ve yorumlara kaynak gösterdiğimi ve kullanılan kaynakların kaynaklar listesinde yer aldığını, tezin çalışılması ve yazımı aşamalarında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

05.01.2022

Mehmet Erşan KALAYCI

TEŐEKKÖR

Bu alıřmanın yűrűtűlmesi sırasında desteęini esirgemeyen, bilgi ve deneyimlerini benimle paylařan danıřmanım Prof. Dr. Kemal TURHAN'a, bilgilerinden faydalandıęım KTÖ Gűęűs Hastalıkları bűlűműnden Dr. Öęr. Üyesi Olcay AYİEK ve Prof. Dr. Funda ÖZTUNA'ya, alıřmalarım sırasında destek olduęu iin KTÖ Tıp Fakűltesi Biyoistatistik ve Tıp Biliřimi Anabilim Dalında alıřan hocalarım ve arkadařlarıma, destek aldıęım tűm KTÖ personeline, desteklerini hibir zaman esirgemeyen aileme teőekkűr ederim.

Mehmet Erřan KALAYCI

İÇİNDEKİLER

Sayfa

İÇ KAPAK SAYFASI

ONAY

BEYAN

TEŞEKKÜR

İÇİNDEKİLER

v

TABLolar DİZİNİ

ix

ŞEKİLLER DİZİNİ

xi

KISALTMALAR, SİMGELER ve FORMÜLLER DİZİNİ

xii

ÖZET

xiv

ABSTRACT

xv

1. GİRİŞ ve AMAÇ

1

2. GENEL BİLGİLER

4

2.1. Sigaranın Kullanımının Tarihçesi

4

2.1.1. Sigara bağımlılığı

5

2.1.2. Dünya’da ve Türkiye’de Sigara Epidemiyolojisi

5

2.1.3. Sigaranın İçeriği

6

2.1.4. Sigaranın sağlığa zararları

7

2.2. Nikotin bağımlılığı

7

2.2.1. Nikotin Fiziksel Bağımlılık

7

2.2.2. Nikotin Psikolojik Bağımlılık

8

2.2.3. Nikotin bağımlılığın Değerlendirilmesi

8

2.2.4. Nikotin bağımlılığı Tedavisi

9

2.2.4.1. Davranış Tedavisi

10

2.2.4.2. Nikotin replasman tedavisi (NRT)

10

2.2.4.3. Bupropion

10

2.2.4.4. Vareniklin

10

2.3. Lojistik regresyon

11

2.3.1. Lojistik Regresyon Varsayımları

12

2.3.2. Lojistik Regresyon Analiz Türleri

12

2.3.2.1. İkili (Binary) Lojistik Regresyon Analizi

12

2.3.2.2. Çoklu Sınıflayıcı (Multinomial) Lojistik Regresyon Analizi	13
2.3.2.3. Çoklu Sıralayıcı (Multiordinal) Lojistik Regresyon Analizi	13
2.3.3. İki Kategorili (Binary) Lojistik Regresyon	13
2.3.3.1. Lojit Model	14
2.3.3.2. Katsayıların Tahmini	16
2.3.3.3. Katsayıların Anlamlılığının Test Edilmesi	16
2.3.4. Çoklu Lojistik Regresyon Analizi	18
2.3.5. Lojistik Regresyon Analizinde Değişken Seçimi	20
2.3.6. Model Uyum İyiiliğinin İstatistikleri	20
2.4. Yapay Zekâ	21
2.5. Makina Öğrenmesi	21
2.5.1. Danışmanlı öğrenme	22
2.5.2. Danışmansız Öğrenme	23
2.5.3. Takviyeli Öğrenme	23
2.5.4. Aşırı Öğrenme (Overfitting) ve Eksik Öğrenme (Underfitting)	24
2.5.5. Çapraz Doğrulama	25
2.5.6. Yanlılık (Bias) ve Varyans	26
2.5.7. Yeniden örneklendirme ve Sentetik veri artırma	27
2.6. Makine Öğrenmesi Algoritmaları (Sınıflandırıcılar)	28
2.6.1. Lojistik Regresyon (LR)	28
2.6.2. Karar Ağaçları (KA)	28
2.6.3. En Yakın k Komşu Algoritması (KNN)	29
2.6.4. Rastgele Orman (RF)	30
2.6.5. Naive Bayes (NB)	31
2.6.6. Destek Vektör Makineleri (SVM)	32
2.7. Yapay Sinir Ağları	34
2.7.1. Yapay Sinir Ağlarının Avantajları	34
2.7.2. Yapay Sinir Ağlarının Kullanım Alanları	34
2.7.3. Geleneksel Algoritmalar ile YSA'ların Karşılaştırılması	35
2.7.4. Biyolojik Sinir Hücresi	35
2.7.5. Yapay Sinir Hücresinin Yapısı	36
2.7.6. Yapay Sinir Ağlarının Yapısı	38
2.7.7. Yapay Sinir Ağlarının Sınıflandırılması	39

2.7.7.1. İleri Beslemeli Yapay Sinir Ağları	39
2.7.7.2. Geri Beslemeli Yapay Sinir Ağları	41
2.8. Derin Öğrenme (DL)	41
2.8.1. Derin Öğrenmeye Giriş	41
2.8.2. Derin Öğrenme Tarihçesi	42
2.8.3. Derin Öğrenme Tanım	44
2.8.4. Konvolüsyonel Sinir Ağları (Evrışimli Sinir Ağı-CNN)	45
2.8.5. Tekrarlı Sinir Ağları (RNN)	47
2.8.6. Kısıtlı Boltzmann Makineleri (RBM)	47
2.8.7. Derin İnanç Ağları (DBN)	47
2.8.8. Derin Oto-Kodlayıcı (AE)	48
3. GEREÇ ve YÖNTEM	49
3.1. Lojistik Regresyon Geriye Doğru Eleme Yöntemi (Backward Stepwise)	49
3.2. Konvolüsyonel Sinir Ağları (CNN)	50
3.2.1. Giriş Katmanı (Input Layer)	51
3.2.2. Konvolüsyon Katmanı (Convolutional Layer)	51
3.2.2.1. Aktivasyon Fonksiyonu	51
3.2.3. Havuzlama katmanı (Max-Pooling Layer)	52
3.2.4. Tam Bağlı Katman (Fully Connected Layer)	52
3.2.5. Çıkış Katmanı (Output Layer)	52
3.2.5.1. Softmax	53
3.3. Google Colab	53
3.4. Verilerin Hazırlanması	54
3.5. Sınıflandırmak için Tasarlanan CNN Yapısı	55
3.6. Veri Analizi	58
4. BULGULAR	60
4.1. Veri setinin Analizi	60
4.2. Lojistik Regresyon Geriye Doğru Adımsal Eleme Yöntemi Sonuçları	70
4.3. Sentetik Olarak Üretilen Verilerin Sonuçları	73
4.4. CNN Tabanlı Sınıflandırıcının Sonuçları	74
5. TARTIŞMA ve SONUÇ	82
6. KAYNAKLAR	86
EKLER	97



TABLÖLAR DİZİNİ

Tablo No	Sayfa
Tablo 1. Sigarada bulunan kimyasal maddeler	6
Tablo 2. Sigaranın vücuttaki zararlı etkileri	7
Tablo 3. Fagerstörn nikotin bağımlılık testi Türkçe versiyonu	9
Tablo 4. Geleneksel algoritmalar ile YSA'ların karşılaştırılması	35
Tablo 5. Biyolojik sinir yapısı ile yapay sinir ağı karşılıkları	36
Tablo 6. Bazı toplama fonksiyonları	37
Tablo 7. Aktivasyon fonksiyonu türleri	38
Tablo 8. Veri seti dağılımı	55
Tablo 9. Sınıflandırmak için tasarlanan CNN modelinin detayları	57
Tablo 10. Hastaların cinsiyete göre dağılımı	60
Tablo 11. Hastaların yaş dağılımı	60
Tablo 12. Hastaların sigara kullanımına ilk başladıkları yaş değişkeni dağılımı	61
Tablo 13. Hastaların düzenli olarak sigara kullanımına başladıkları yaş	61
Tablo 14. Hastaların medeni durumuna göre dağılımı	61
Tablo 15. Hastaların eğitim durumuna göre dağılışı	62
Tablo 16. Hastaların gelir düzeyine göre dağılışı	62
Tablo 17. Hastaların çocuk sayılarına göre dağılımı	62
Tablo 18. Hastaların günlük tüketilen sigara miktarına göre dağılışı	62
Tablo 19. Hastaların sigara tüketimine (paket/yıl) göre dağılışı	63
Tablo 20. Hastaların sigaraya başlama nedenlerine göre dağılımı	63
Tablo 21. Yıllar içerisinde sigara miktarındaki değişiklere göre dağılımı	63
Tablo 22. Hastaların kullandıkları sigara markasına göre dağılım	64
Tablo 23. Hastaların sigarayı bırakmayı isteme nedenlerinin dağılımı	64
Tablo 24. Hastaların deneme sayısına göre dağılımı	64
Tablo 25. Hastaların deneme süresine göre dağılımı	64
Tablo 26. Sigarayı bıraktıklarında karşılaştığı zorluklara göre dağılımı	65
Tablo 27. Hastaların sigara içme isteğini arttıran nedenlere göre dağılımı	65
Tablo 28. Hastaların sistem sorgulamasındaki semptomlara göre dağılımı	66
Tablo 29. Hastaların soy geçmişine göre dağılımı	66
Tablo 30. Hastaların özgeçmişine göre dağılımı	67

Tablo 31.	Hastaların yakın çevresinde sigara kullanılan kişilere göre dağılımı	67
Tablo 32.	Hastaların ebeveynlerinin sigara içme durumuna göre dağılımı	67
Tablo 33.	Hastaların hobilerine göre dağılımı	68
Tablo 34.	Hastaların uygulanan tedavi yöntemine göre dağılımı	68
Tablo 35.	Hastaların destek alma şekline göre dağılımı	68
Tablo 36.	Hastaların Fagerstörn nikotin bağımlılık testi verileri	69
Tablo 37.	Hastaların laboratuvar verileri	70
Tablo 38.	Bağımsız değişkenleri içeren modelin özeti	71
Tablo 39.	Eliminasyon yöntemi kullanılarak elde edilen değişkenler	71
Tablo 40.	Değişkenlerin tanımı	72
Tablo 41.	Hosmer Lemeshow testi	72
Tablo 42.	Eliminasyon yöntemi sonucunda sınıflandırma tablosu	73
Tablo 43.	Öğrenme oranları karşılaştırılması	75
Tablo 44.	Farklı optimizasyon algoritmaları karşılaştırması	75
Tablo 45.	Farklı epoch değerlerinin karşılaştırılması	76
Tablo 46.	Sistemi eğitirken farklı hiperparametreler için oluşturulan modeller	76
Tablo 47.	En başarılı modelin detayları	77
Tablo 48.	En başarılı model için 5 kat çapraz doğrulama	78
Tablo 49.	En başarılı modelin karışıklık (confusion) matrisi sonuçları	79
Tablo 50.	Sınıflandırıcı metrikleri	79
Tablo 51.	Sınıflandırıcı model çıktıları	80
Tablo 52.	Veri seti için sınıflandırıcıların karşılaştırılması	80
Tablo 53.	Sınıflandırma hata oranları	81

ŞEKİLLER DİZİNİ

Şekil No	Sayfa
Şekil 1. Lojistik fonksiyonu	14
Şekil 2. Lojistik regresyon eğrisi	15
Şekil 3. Sınıflandırma ve regresyon örneği	22
Şekil 4. Aşırı öğrenme ve eksik öğrenme	25
Şekil 5. Çapraz doğrulama yöntemi	26
Şekil 6. Bias-Varyans dengesi	27
Şekil 7. Lojistik regresyon sınıflandırıcı	28
Şekil 8. En uygun hiper düzlem	32
Şekil 9. Destek vektörleri	33
Şekil 10. Biyolojik sinir hücresinin yapısı	36
Şekil 11. Yapay sinir ağı örneği	37
Şekil 12. Yapay sinir ağının yapısı	39
Şekil 13. İleri beslemeli çok katmanlı sinir ağının yapısı	40
Şekil 14. Çok katmanlı ağların yapısı	41
Şekil 15. Geri beslemeli YSA	41
Şekil 16. Derin öğrenme hiyerarşisi	42
Şekil 17. İlk derin ağ mimarisi	43
Şekil 18. Derin sinir ağı yapısı	44
Şekil 19. LeNet ağının mimarisi	46
Şekil 20. CNN ağının temel mimarisi	50
Şekil 21. Veri seti için kurulan CNN modeli	55
Şekil 22. Gerçek veri ile yapay verinin dağılımı	74
Şekil 23. Veri setinin yapısı	74
Şekil 24. Eğitim ve test doğruluk grafiği	77
Şekil 25. Eğitim ve test hata grafiği	77
Şekil 26. Eğitim ve doğrulama doğruluk grafiği	78
Şekil 27. Eğitim ve doğrulama hata grafiği	78

KISALTMALAR, SİMGELER ve FORMÜLLER DİZİNİ

Kısaltmalar

AE	Derin oto-kodlayıcı
AL	Artificial Intelligence (Yapay Zekâ)
ALL	Akut lenfoblastik lösemi
CNN	Konvolüsyonel sinir ağı (evrişimli sinir ağı)
DA	Nörotransmitter dopamin
DBN	Derin inanç ağları
DL	Derin öğrenme (deep learning)
DSÖ	Dünya Sağlık Örgütü
FN	Yanlış negatifler
FNBT	Fagerstörn nikotin bağımlılık test
FP	Yanlış pozitifler
KA	Karar ağaçları (decision tree)
KNN	En yakın k komşu algoritması
KOAH	Kronik obstrüktif akciğer hastalığı
LR	Lojistik regresyon
ML	Makine öğrenmesi (machine learning)
MLP	Çok katmanlı algılayıcı (multi layer perceptron)
MÖ	Milattan önce
NA	Nükleus accumbens
NB	Naive bayes sınıflandırma algoritması
NLP	Doğal dil işleme
NN	Sinir ağı (neural network)
NRT	Nikotin replasman tedavisi
OCR	Optik karakter tanıma
RBM	Kısıtlı boltzmann makineleri
RNN	Tekrarlı sinir ağları
RF	Rastgele orman
ROC	Alıcı işlem karakteristikleri (receiver operating characteristic)
SVM	Destek vektör makineleri
TN	Doğru negatifler
TP	Doğru pozitifler

VTA	Ventral tegmental bölge
YSA	Yapay sinir ağıları
Simgeler	
β	Bağımsız değişken katsayı
ε	Hata değeri
n	Örneklem büyüklüğü
π	Olasılık
p	Olasılık değeri
R	Belirtme katsayısı
Y	Bağımlı değişken
X	Bağımsız değişken
x	Bağımsız değişkenler vektörü
W	Wald istatistiği
∞	Sonsuz

ÖZET

Derin Öğrenme Yaklaşımı ile Sigara Bırakma Tedavisinin Belirlenmesi için Karar Destek Sisteminin Geliştirilmesi

Dünya Sağlık Örgütü (DSÖ), sigara bağımlılığının dünyada en yaygın bağımlılık olduğunu ve her yıl 6 milyon kişinin sigara kullanımına bağlı hastalıklardan hayatını kaybettiğini bildirmiştir. Dünyada ve ülkemizde sigara bırakma oranları çok düşüktür ve kişiye göre farklılık göstermektedir. Bunun için de doktorlar, hastalar için uygun tedavi yöntemini belirlerken bireysel farklılıkları dikkate alan tedavi planları yapmalıdır. Bu çalışma, tedavide uzmana yardımcı olmak için bilgisayarlı klinik karar destek sistemlerini ve hasta özelliklerine göre kişiselleştirilmiş hasta önerileri sağlayan kişiselleştirilmiş bir sağlık bakım sistemini tanıtmaktadır.

Çalışmaya Trabzon Farabi Hastanesi Göğüs Hastalıkları Anabilim Dalı Sigara Bırakma Polikliniğine 2015-2020 yılları arasında başvuran 383 hasta dahil edildi. Bu hastalardan elde edilen veriler kullanılarak sigara bırakma başarısını etkileyen faktörler IBM SPSS23 ve R paket programı kullanılarak analiz edildi. Lojistik regresyon geriye doğru eliminasyon yöntemi kullanılarak 383 hastadan elde edilen faktörlerden sigara bırakma başarısında etkili olduğu ortaya çıkan 12 faktör tespit edildi. Son yıllarda gelişmekte olan derin öğrenme yöntemi, tıbbi verilerin analiz edilmesinde ve hastalıkların teşhisinde kullanılmaktadır. Bu amaçla bu tez çalışmasında, bireysel farklılıklara göre sigara içenlerin sigara bırakma oranlarını tahmin edebilen derin bir öğrenme modeli oluşturulmuştur. Derin öğrenme yaklaşımının bir yöntemi olan konvolüsyonel sinir ağı (CNN) tabanlı karar destek sistemi, 1000 örneklem 12 faktörden oluşan bir veri seti kullanılarak Google Colaboratory platformunda geliştirilmiştir. Bu veri setinde verilerin %80'i eğitim ve %20'si test verisi olarak rastgele bölünen CNN ağında %79'luk başarı yüzdesi elde edilmiştir. 200 test verisi üzerinde geliştirilen en iyi CNN modeli için %64 duyarlılık, %88 özgüllük ve %79 doğruluk değerleri elde edilmiştir. CNN'nin yöntemi 7 farklı makine sınıflandırıcıları (RF, DT, NB, SVM, LR, KNN ve MLP) ile karşılaştırılmıştır. CNN yönteminin %79 doğrulukla diğer makine sınıflandırıcıları üzerinde etkili olduğu kanıtlanmıştır. Bu uzman sistem sayesinde sigara bırakma polikliniğine başvuran hastalarda sigara bırakma oranları sınıflandırılmıştır.

Anahtar Kelimeler: Derin öğrenme, Karar destek sistemi, Konvolüsyonel sinir ağı, Makine öğrenmesi, Nikotin, Sigara bırakma

ABSTRACT

Developing Decision Support System for Determining of Smoking Cessation Therapy with Deep Learning Approach

The World Health Organization (WHO) reported that cigarette addiction is the most common addiction in the world, and every year 6 million people die from diseases related to smoking. Smoking cessation rates in the world and in our country are very low and vary according to the individual. For this, physicians should make treatment plans that take individual differences into account while determining the appropriate treatment method for patients. This study introduces computerized clinical decision support systems to assist the treatment professional and a personalized healthcare system that provides personalized patient recommendations based on patient characteristics.

383 patients who applied to the Smoking Cessation Outpatient Clinic of Trabzon Farabi Hospital Chest Diseases Department between 2015-2020 were included in the study. Using the data obtained from these patients, factors affecting smoking cessation success were analyzed using IBM SPSS23 and R package program. Among the factors obtained from 383 patients using the logistic regression inverse elimination method, 12 factors were identified that turned out to be effective in smoking cessation success. The deep learning method, which has been developing in recent years, is used in analyzing medical data and diagnosing diseases. For this purpose, in this thesis, a deep learning model that can predict people's smoking cessation rate of smokers based on individual differences has been created. Convolutional neural network (CNN) based decision support system, which is a method of deep learning approach, has been developed on the Google Colaboratory platform using a data set consisting of 1000 sample and 12 factors. In this data set, a success rate of %79 was obtained in the CNN network where 80% of the data was divided into training and 20% test data randomly. For the best CNN model developed on 200 test data, %88 specificity, %64 sensitivity, and %79 accuracy values were obtained. CNN's method has been compared with 7 different machine classifiers (RF, DT, NB, SVM, LR, KNN and MLP). The CNN method has proven to be effective on other machine classifiers with an accuracy of %79. Thanks to this expert system, smoking cessation rates were classified in patients who applied to the smoking cessation clinic.

Keywords: Convolutional neural network, Deep learning, Decision support system, Machine learning, Nicotine, Quitting smoking

1. GİRİŞ ve AMAÇ

Son yıllarda teknolojiadaki ilerlemeler ile insan beyninin yapısının çalışma mantığını taklit ederek karar verme ve öğrenme yetenekleri kazanmaya yönelik yapay zekâ (AI) tekniklerinin başarısı, tıp alanındaki kullanımlarını artırmıştır. Yapay zekâ yöntemlerinin en ayırt edici özelliği, karmaşık problemlerin çözülmesine imkân sağlaması, genelleme yapabilme, yorumlama ve karar verme becerisine sahip olmasıdır. Böylelikle insanlar tarafından çözülmesi zor olan problemleri çözmek için yapay zekâ teknikleri kullanılmıştır (1).

Yapay zekanın bir alt dalı olan istatistiksel öğrenme olarak da bilinen makine öğrenimi (ML), verilerden matematiksel modeller çıkararak makinelerin insanlar gibi öğrenmesine olanak tanıyan bilimdir. Makine öğrenmesi, özellikle askeri, eğitim ve sağlık hizmetleri olmak üzere birçok alanda kullanılmaktadır. Sağlık hizmetlerinde kullanılan makine öğrenimi, semptomlar, davranışlar, biyokimyasal ve patolojik değişkenler dahil olmak üzere çeşitli öznitelikleri incelemek için tasarlanmıştır. ML, sağlık alanında hastalıkları sınıflandırmak ve en uygun tedaviyi belirlemek için en sık kullanılan yöntemlerden biridir (2).

Derin öğrenme (DL), yapay sinir ağları (YSA) adı verilen beynin yapısına ve işlevlerine dayanan algoritmalarla ilgilenen bir makine öğrenimi alt dalıdır. Son yıllarda oldukça popüler olan derin öğrenme yaklaşımı sayesinde tıbbi bulgularla ilgili oldukça başarılı çalışmalar yapılmıştır. Derin öğrenme terimi, Hinton'un 2006 yılında katmanlı sinir ağlarının verimli bir şekilde eğitilebileceğini belirtmesinin ardından literatürde sıkça kullanılmaya başlandı (3). Derin öğrenme yaklaşımlarının bir yöntemi olan konvolüsyonel yapay sinir ağları (CNN), omurgalıların görme merkezinden esinlenilerek geliştirilmiştir. Konvolüsyonel sinir ağları (CNN), alanında yapılan araştırmalar her geçen gün artmakta ve uygulama alanları gittikçe çoğalmaktadır. Konvolüsyonel yapay sinir ağları, hastalıkları teşhis ederken tıbbi verilere dayanarak kanıya varabilmektedir. CNN'nin hastalık teşhisinde sınıflandırma ve tahmin problemlerine uygulandığında yüksek performans gösterdiği belirtilmiştir (4, 5). Sipes ve Li (2018) tarafından yayınlanan bir çalışma için ALL-IDB ve Cella Vision veri seti, Akut Lenfoblastik Lösemi (ALL) kanser türünü sınıflandırmak için birleştirildi. Görüntüler daha sonra 257x257 boyutunda yeniden ölçeklendi ve RGB renk uzayında kullanıldı. Sınıflandırma için KNN, sinir ağı (NN) ve CNN modelleri kullanılmıştır. CNN modeli %92'lik doğruluk oranıyla en başarılı model

olduğunu kanıtlamıştır (6). Das ve arkadaşları (2019) tarafından yapılan bir çalışmada, üç önemli beyin tümörünü (meningioma, glioma ve hipofiz tümörü) sınıflandırmak için 233 hasta hakkında veri toplanmıştır. Orijinal görüntüler 512×512 boyutundadır. Görüntüler daha sonra 112×112 boyutunda yeniden ölçeklendi ve görüntüler CNN modeli kullanılarak sınıflandırıldı. Önerilen CNN modeli %94 başarı doğruluğu göstermiştir (7).

Sigarayı bırakmak için literatürde yapılmış önceki çalışmalar, temel olarak bağımsız faktörleri belirlemeye ve her faktör için olasılık oranını açıklamaya odaklandı (8). Bununla birlikte, hastalar belirlenen faktörlerin farklı kombinasyonlarına sahip olabilirler. Bunun sonucunda klinik uygulamada her bir kişi için çelişkili sonuçlara ve zor yorumlara yol açabilir. Bu durum tahmin modelleri kullanılarak önlenir. Bu konuda bir makine öğrenimi sınıflandırma modeli oluşturmaya yönelik ilk girişim Coughlin ve arkadaşları tarafından yapılmıştır. Coughlin ve arkadaşları tarafından 2018 yılında yayınlanan bir çalışmada grup bilişsel-davranışçı terapi (CBT) gören sigara kullanan hastalar iki gruba ayrıldı. Hastaların sigarayı bırakma durumlarını tahmin etmek için önemli faktörler belirlendi. Bırakma sonuçlarını tahmin etmek için makine öğrenimi ile geliştirilen bir karar ağacı modeli kullanıldı. Karar ağacı modeli ile yaklaşık %64'lük bir ortalama doğru sınıflandırma oranını tahmin edebilen bir karar destek sistemi geliştirilmiştir (9). Kharabsheh M. ve arkadaşları tarafından 2019 yılında gerçekleştirilen çalışmada yaş, ikamet ve eğitim düzeyi gibi sigara içenlerle ilgili 19 faktör kullanılarak Ürdün'lü tütün kullanan kadınlar için nikotin bağımlılık düzeyini tahmin eden bir sınıflandırıcı geliştirilmiştir. Destek vektör makinesi, Naive Bayes, en yakın komşuluk ve karar ağaçları sınıflandırıcıları olmak üzere 4 farklı sınıflandırıcı geliştirilmiştir. Destek vektör makinesi %82 duyarlılık ve %43 özgüllük değeri ile sonucu en başarılı tahmin edebilen bir karar destek sistemi geliştirilmiştir (10). Lai ve arkadaşları tarafından 2021 yılında yayınlanan bir çalışmada Kuzey Tayvan'daki bir tıp merkezinde 4875 hastanın katılımıyla sigara bırakmanın sonucunu tahmin etmek için bir model geliştirildi. Hasta verileri, Yapay sinir ağı (YSA), destek vektör makinesi (SVM), rastgele orman (RF), lojistik regresyon (LR), k-en yakın komşu (KNN) ve saf Bayes (NB) olmak üzere farklı sınıflandırıcılar kullanılarak eğitildi. Yapay sinir ağı (YSA) algoritması, %64 doğruluk oranı ile sonucu en başarılı tahmin edebilen karar destek sistemi geliştirilmiştir (11).

Bu tez çalışmasında sigara bırakma polikliniklerine başvuran hastalarda düşük başarı oranları nedeniyle sigara bırakma başarısını etkileyen bireysel faktörleri belirlemeye

ve hekimin tedavi sürecini şekillendirmesine yardımcı olacak klinik karar destek sistemi geliştirilmesi amaçlanmıştır.

Günümüzde dünya nüfusunun %30'u sigara içmektedir. Dünyada her yıl yaklaşık 6 milyon insan sigara kullanımına bağlı hastalıklardan ölmektedir (12). Bu nedenle DSÖ, sigarayı en yaygın halk sağlığı sorunlarından biri ve önlenabilir erken ölüm nedenlerinden biri olarak tanımlamaktadır (13). Sigara vücuda zarar veren ve birçok hastalığa neden olan birçok zehirli madde içermektedir. Kanser, kalp ve akciğer hastalıkları özellikle KOAH gibi birçok hastalığa neden olmasına rağmen uzun yıllardır yaygın olarak kullanılmaktadır. Sigara içmek sadece kişinin kendi sağlığına zarar vermez pasif dumana maruz kalan kişilere de zarar vermektedir. Pasif dumana maruz kalmak ciddi ve ölümcül sağlık sorunlarına neden olur. Yetişkinlerin yaklaşık üçte biri düzenli olarak pasif dumana maruz kalmaktadır. Sigara kullanımına bağlı hastalıklar genellikle sigara kullanımının başlangıcından uzun yıllar sonra ortaya çıkar. Sigara kullanımının aktif ve pasif sigara dumanı maruziyet nedeniyle tüm toplumu endişelendiren bir halk sağlığı sorunudur (14). Sigaraya karşı yoğun mücadeleye rağmen, sigarayı bırakma oranları hala düşüktür. Sigara bırakma polikliniklerinde yoğun tedavi gören hastalarda da bırakma başarısı düşüktür ve kişiye göre farklılık göstermektedir. Bu nedenle bireysel faktörler göz önüne alınarak tedavi sürecini bu faktörlere göre şekillendirmek ve sigara bırakma başarısını arttırmak insan sağlığı ve toplum sağlığı için önemlidir (12).

Bu teşhis sistemi, derin öğrenme algoritmalarından konvolüsyonel sinir ağı (CNN) yöntemi kullanılarak geliştirilmiştir. Bu çalışmada Karadeniz Teknik Üniversitesi Farabi Hastanesi Göğüs Hastalıkları Anabilim Dalı Sigara Bırakma Polikliniği'ne 2015-2020 yılları arasında başvuru yapmış 18 yaş üzeri ve çalışmaya katılmak isteyen 383 hasta incelendi. Böylece 383 hastadan elde edilen lojistik regresyon ile belirlenen 12 faktörden oluşan bir veri seti kullanılarak sistem eğitildi. Böylelikle, geliştirilen uzman sistem yardımı ile sigara bırakma kliniğine başvuran yeni bir hasta için sigara bırakma düzeylerinin sınıflandırılması otomatik olarak yapılabilmektedir. Bu çalışmanın kapsamı sigara bağımlılığı ile sınırlıdır. Alkol ve diğer madde bağımlılıkları bu çalışma kapsamının dışındadır.

2. GENEL BİLGİLER

2.1. Sigaranın Kullanımının Tarihçesi

Tütün, Güney Amerika'da doğal olarak yetişen bir bitkidir. Bitkiler sistematğinde patlıcangiller ailesinde bulunan tütün ölümcül bir bitki olan zehirli it üzümü ile aynı ailedendir. Tütün yaprağının yapısında bulunan nikotin keyif verici ve bağımlılık yapıcı özelliğe sahip organik azotlu bir maddedir. Tütünün Amerika'da MÖ 6000 civarında yetiştirilmeye başladığı tahmin edilmektedir. MÖ 1500 yıllarında Orta Amerika'da yaşayan yerlilerin ilk kez tütünü kişisel kullanımları için çiğneyerek kullanmaya başladığı belirtilmiştir (15). Yerliler tütünü başlarda dini ayinlerde kullanmış olup, ilerleyen zamanlarda tıbbi uygulamalar gibi birçok alanda kullanılmaya başlanmıştır. Tütünün hastalıklar üzerinde iyileştirici bir etken olduğuna inanılıyordu ve bir ağrı kesici olduğu kadar yaraları sarmak için de kullanılıyordu (16).

15. yüzyılın sonlarında, Kristof Kolomb'un Amerika kıtasını keşfi ile Avrupa kıtasının tütün ile tanışması gerçekleşmiştir. Kolomb, Küba'ya seyahati sırasında karşılaştığı yerlilerin burada tütünün dini ayinlerde ve şöenlerde çubuklarla tütürülen bazen de ağızda çiğnenerek kullanıldığını görmüştür (17). Yerliler tütünü Amerika'ya yolu düşen denizcilere ikram etmişlerdir. Kısa süre sonra, bağımlılık geliştiren denizciler tütünü Avrupa'ya getirmiş ve bitki tüm Avrupa'da yetiştirilmeye başlanmıştır (18).

Fransa'nın Portekiz elçisi Jean Nicot, 1559 yılında Fransız kraliçesine tütünü hediye etmesiyle birlikte tütünün Avrupa'da yayılmasını sağlamıştır. Kraliçenin migren ağrısının tedavisinde tütünü alına sürdüğünde baş ağrısını hafiflettiğinden dolayı çok etkilenmiş bunun sonucunda saray bahçesinde yetiştirilmeye başlanmıştır (19). 1828 yılında tütünün içinde bulunan zehirli madde olan nikotin, göstermiş olduğu çabaları sonucunda elçinin ismi olan Nicot'tan gelmektedir (20). Tütünün hastalık üzerinde iyileştirici bir ilaç olduğu düşüncesi dünyada yaygın hale gelmesini kolaylaştırmıştır.

16. yüzyılın başlarında ticari olarak tütün üretimine Amerika'da başlanmıştır. 1881 yılında sigara saran makinaların icadı ile yeni bir sanayi kolu doğmuştur. 1913 yılında ise R.J. Reynolds'un kendi şirketinin ürettiği ilk sigara markası olan Camel dünyaya tanıtılmış ve modern anlamda sigaranın doğuşu meydana gelmiştir (21).

16.yüzyılda Tütün Anadolu'ya ilk kez İstanbul limanından İngiliz, İtalyan, İspanyol denizciler ve tacirler tarafından getirilmiş ve Osmanlı halkı tarafından da kullanılmaya

başladığı Peçevi İbrahim Efendi'nin “Peçevi Tarihi” adlı eserinde anlatılmıştır (22). Osmanlı'da tütün yetiştiriciliği ilk kez İzmir Selçuk'ta yapılmıştır. 1884 yılında Osmanlı devletinde ilk sigara fabrikası İstanbul Cibali sigara fabrikası II. Abdülhamid döneminde kurulmuştur. Türkiye'de tütünün üretilmesi ve işlenmesi amacıyla 1924 yılında “Ulusal Tekel” kurulmuştur. 1925 yılında Mustafa Kemal Atatürk, Osmanlı Devleti'nin borçlarına karşılık Fransız Reji şirketinin kontrolüne verilen tütün tekellerinin tüm hak ve alacaklarını ödemiştir. Böylece tütün ve tütün ürünleriyle ilgili tüm hizmetlerin devlet tarafından yürütülmesi karara bağlanmıştır (23).

2.1.1. Sigara bağımlılığı

Bağımlılık, bireyin madde veya davranışları üzerinde kontrolünü kaybetmesi ve artan miktarlarda tekrarlama isteğiyle ortaya çıkan biyopsikososyal bir bozukluktur. Sigara bağımlılığı kişinin beynini ve davranışlarını olumsuz etkileyen bir hastalıktır. DSÖ, madde kullanımına bağlı bağımlılığı şu şekilde tanımlamıştır:

“Kullanılan bir psikoaktif maddeye kişinin daha önceden değer verdiği diğer uğraşlardan ve nesnelerden belirgin olarak daha yüksek bir öncelik tanıma davranışdır” (DSÖ, 2020).

Sigara içme veya dumanının solunması zamanla bireylerde psikolojik ve fiziksel bağımlılığa neden olur. Tütün ürünlerinde bulunan nikotin, bağımlılık yapan bir kimyasaldır. Sigara içmek diğer bağımlılık türlerine nazaran daha çok alışkanlık yapıcı daha az zevk verici bir bağımlılık türü olarak sınıflandırılır.

2.1.2. Dünya’da ve Türkiye’de Sigara Epidemiyolojisi

Sigara bağımlılığı, dünyadaki en ciddi halk sağlığı tehditlerinden biridir ve dünyada yılda 8 milyondan fazla insanın ölümüne neden olmaktadır. Bu ölümlerin 7 milyondan fazlası aktif tütün kullanımından kaynaklanırken, yaklaşık 1.2 milyonu pasif olarak dumana maruz kalınmasından dolayı oluşan ölümlerdir (12). DSÖ verilerine göre dünyada 942 milyon erkek ve 175 milyon kadının aktif olarak sigara kullandığını bildirmiştir. Dünya genelinde 2 milyara yakın kişi sigara içmektedir. Dünya çapında 1.3 milyar tütün kullanıcısının %80'inden fazlası, tütünle ilgili hastalık ve ölüm oranlarının en yüksek olduğu düşük ve orta gelirli ülkelerde yaşıyor. Dünya’da 1950 ve 2000 yılları arasında sigaranın neden olduğu hastalıklar nedeniyle yaklaşık olarak 60 milyon kişi hayatını kaybetmiştir. DSÖ verilerine göre Kiribati, Karadağ, Yunanistan, Doğu Timur ve

Rusya 15 yaş üstü en çok sigara içilen ilk 5 ülke arasında yer almaktadır. Türkiye bu sıralamada kırkinci sıradadır (24).

Türkiye’de 1980-1990 yılları arasında sigara tüketimi hızla arttı. Bu büyüme 1990’ların sonuna kadar devam etti, daha sonra büyüme hızı yavaşladı. 2000’li yılların ortalarında tütün ve sigara kullanımı düşmeye başladığı görüldü. Türkiye’de 15 yaş ve üstü yetişkinler arasında sigara kullanım oranı %31.2’dir. Bu oran erkeklerde %48, kadınlarda ise %15’tir. Kişilerin her gün sigara içme oranı %27.4’tür. Günlük sigara tüketiminin yaş aralıklarına göre dağılışı incelendiğinde 25-44 yaş arasındaki bireylerin daha fazla sigara kullandıkları görülmüştür. Eğitim düzeyleri göz önüne alındığında hem erkeklerde hem de kadınlarda sigara kullanım sıklığı lise düzeyine kadar artış göstermekte, üniversite eğitimi sonrasında bir azalış olduğu saptanmıştır. Ülkemizde yıllar içinde kişilerin sigara kullanım sıklığı azalmasına rağmen ciddi sağlık sorunu olmaya devam etmektedir (25).

2.1.3. Sigaranın İçeriği

Sigara, ince bir kâğıt içine sıkıştırılarak sarılmış bir tütün içme yöntemidir. Sigara ve sigara dumanında 4000’den fazla zehirli madde bulunduğu tespit edilmiştir. Bu maddelerin çoğu tümör gelişimini hızlandırıcı özellik gösterir. Sigara dumanı tütün bitkisi yapraklarının tam yanmamasından kaynaklanır. Sigara dumanında bulunan maddelerin çoğu gaz veya tanecik haldedir. Başlıca etki ve özellikleri gösterilmiştir (Tablo 1).

Tablo 1. Sigarada bulunan kimyasal maddeler (Uzunca’dan, 19)

Tanecik halinde	Başlıca etki	Gaz halinde	Başlıca etki
Tar (katran)	Mutajenik/karsinojenik	Karbonmonoksit	Oksijen kullanımını engeller
Nikotin	Doza-bağımlı uyarıcı	Nitrojen oksitler	İrritan, pro-inflamatuvar, siliotoksik
Aromatik hidrokarbonlar	Mutajenik/karsinojenik	Aldehitler	İrritan, pro-inflamatuvar, siliotoksik
Fenol	İrritan, Mutajenik/karsinojenik	Hidroksisizyalik asit	İrritan, pro-inflamatuvar, siliotoksik
Kresol	İrritan, Mutajenik/karsinojenik	Akrolein	İrritan, pro-inflamatuvar, siliotoksik
B-naftilamin	Mutajenik/karsinojenik	Amonyak	İrritan, pro-inflamatuvar, siliotoksik
Benzopiren	Mutajenik/karsinojenik	Vinil kloride	Mutajenik/karsinojenik
Ketakol	Mutajenik/karsinojenik	Nitrozaminler	Mutajenik/karsinojenik
İndol	Tümör hızlanması	Hidrazin	Mutajenik/karsinojenik
Karbazol	Tümör hızlanması		

2.1.4. Sigaranın sađlıđa zararları

Sigara içmek vücudun hemen hemen her organına zarar verdiği yapılan araştırmalar neticesinde kanıtlanmıştır. Bu zararlı ve olumsuz etkilerin bazıları hemen ortaya çıkarken bazıları herhangi bir semptom göstermeden ilerleyerek tedavisi olmayan hastalıklara dönüşebilir. Sigaranın dumanına maruziyet sonrasında insan vücudunda meydana gelen zararlar gösterilmiştir (Tablo 2).

Tablo 2. Sigaranın vücuttaki zararlı etkileri

Organlar	Etkileri
Akciğer	Akciğer kanseri, KOAH (Kronik obstrüktif akciğer hastalığı), Pnömoni
Kalp	Miyokard infarktüsü, aterosklerozda hızlanma, koroner arter hastalığı
Ağız, boğaz, burun	Larinks kanseri, ağız kokusu, dişlerde sararma, tat duyusunda ve koku almada azalma
Sindirim sistemi	Peptik ülser, mide kanseri
Kemikler	Osteoporoz
Cilt	Ciltte erken kırışıklar oluşması
Genitoüriner sistem	Mesane kanseri, impotans, infertilite, düşük doğum, kilolu bebek doğurma, serviks kanseri
Göz	Körlük, katarakt
Pankreas	Pankreas kanseri
Bağırsak	Kolon kanseri

2.2. Nikotin bağımlılığı

Nikotin, tütün bitkisi de dahil olmak üzere çeşitli bitki türleri tarafından üretilen nitrojen içeren bir kimyasaldır. Nikotinia ailesine ait bitkilerin yapraklarından elde edilir (26). Nikotin, sigara içerken veya ince kıyılmış tütünü emerken kullanılır. Nikotin, beyin ve vücut arasındaki mesaj alışverişini hızlandıran uyarıcı bir ilaçtır. Normal bir sigara 20 mg. nikotin bulundurmasına rağmen yakılıp tüketildiği için 1-1.5 mg. nikotin alınır. Tek başına kansere neden olmamakla birlikte veya aşırı derecede zararlı olmadığı bilinen nikotin ağır bir şekilde bağımlılık yapar ve insanları tütün bağımlılığının son derece zararlı etkilerine maruz bırakır (27).

2.2.1. Nikotin Fiziksel Bağımlılık

Nikotin, sigara kullanmaya teşvik eden bir tütün kimyasaldır (28). Nikotin vücuda hızla yayılır ve kan-beyin bariyeri yoluyla beyne geçer. Kan dolaşımına girdikten sonra nikotin, beyne bağlandığı ve kolinerjik reseptörler adı verilen reseptörleri aktive ettiği yere gider. Bu reseptörler beyinde ve vücudun kaslar, kalp, böbrek üstü bezleri ve diğer hayati

organlar gibi diğer bölgelerinde bol miktarda bulunur. Tipik olarak bu reseptörler, beyindeki sinir uçlarında ve periferik sinir sistemindeki sinirlerde üretilen nörotransmitter asetilkolin tarafından aktive edilir. Reseptörlerin asetilkolin ile uyarılması, sağlıklı solunum, kalp fonksiyonu ve kas hareketinin yanı sıra hafıza gibi bilişsel fonksiyonların sürdürülmesinde önemli bir rol oynar. Nikotin, asetilkoline benzer bir yapıya sahip olduğu için kolinerjik reseptörleri aktive edebilir. Bununla birlikte, asetilkolinin aksine, nikotin normal beyin fonksiyonunu bozarak kimyasal değişikliklere ve bağımlılığa neden olur. Vücuda sigara yoluyla giren nikotin, reseptörler adı verilen beyin yapılarını harekete geçirir. Bu reseptörler aktive edildiğinde beyinde dopamin adı verilen bir kimyasal salgılanır (29). Dopamin nikotin bağımlılığı sürecinin büyük bir parçasıdır. Diğer bağımlılık yapıcı ilaçlar gibi, nikotin de yararlı davranışların (susadığında su içmek gibi) ödüllendirildiği ve pekiştirildiği beynin ödül sisteminin çekirdek nöronlarına bağlanır. Beynin ventral tegmental bölge (VTA) adı verilen bir bölgesinde yer alan bu ödül sistemi nöronları, dopaminerjik nöronlar olarak adlandırılan, nörotransmitter dopaminin (DA) nükleus accumbens (NAc) adı verilen yakın bir beyin bölgesinde salgılanmasını tetikler. Nikotin bu nöronlara bağlandığında aktivitelerini arttırırlar, NAc'yi dopamin ile doldururlar, bu da zevk ve ona yol açan davranışları tekrarlama eğilimine neden olur. Bu zevk ve eğilim, bağımlılık yapar (30, 31).

2.2.2. Nikotin Psikolojik Bağımlılık

Nikotin, tütünde hoş duygular uyandıran ve kişinin rahatsız edici duygulardan uzaklaştıran bir ilaçtır. Nikotin, nöronların fazla dopamin salgılanmasına neden olur, bu da kişinin rahat ve keyifli hissetmesini sağlar (29). Ancak bu iyi his uzun sürmez, bu yüzden tekrar iyi hissetmek için nikotin almak ister. Nikotin almak, adrenal korteksten epinefrin boşalmasına neden olarak ani bir glikoz salınımına neden olur. Uyarılmayı depresyon ve yorgunluk izler, bu da kullanıcıyı daha fazla nikotin aramaya yönlendirir. Zamanla, kişi duygusal olarak nikotine bağımlı hale gelir. Bu duygusal bağımlılık, sigarayı veya diğer tütün ürünlerini bırakmaya çalıştığında hoş olmayan yoksunluk belirtileri ortaya çıkar. Nikotin aslında kişilerin beyin kimyasını ve duygularını etkiler (30, 31).

2.2.3. Nikotin Bağımlılığın Değerlendirilmesi

Klinik uygulamalarda sigara bağımlılığının tespit edilmesinde yaygın kullanılan test Fagerstörn Nikotin Bağımlılık Testi (FNBT)'dir (32). Karl Fagerstörn tarafından sigara bağımlılık düzeyini saptamak için geliştirilmiş olan bu ölçek 6 adet sorudan oluşmaktadır.

Bu sorulara alınan yanıtlara göre puanlar toplanır ve bağımlılık düzeyi hesaplanır (33). Testin Türkçe geçerlik ve güvenirliği Uysal ve ark. (2004) tarafından yapılmış ve testin Türkçe versiyonunun güvenirliğinin orta derecede güvenilir olduğu (Cronbach's alfa:0.56) ve klinik uygulamalarda kullanılabileceği sonucuna varılmıştır (34, 35). Tablo 3'de Fagerstörn Nikotin Bağımlılık Testi Türkçe versiyonu gösterilmiştir.

Tablo 3. Fagerstörn Nikotin Bağımlılık Testi Türkçe versiyonu (Uysal'dan, 34)

“Soru 1: İlk sigaranızı sabah uyandıktan ne kadar süre sonra içersiniz?”
“a. Uyandıktan sonraki ilk 5 dakika içinde (3 puan) “
“b. 6- 30 dakika içinde (2 puan)”
“c. 31- 60 dakika (1 puan) “
“d. 1 saatten fazla (0 puan) “
“Soru 2: Sigara içmenin yasak olduğu örneğin; otobüs, hastane, sinema gibi yerlerde bu yasağa uymakta zorlanıyor musunuz? “
“a. Evet (1 puan) “
“b. Hayır (0 puan)”
“Soru 3: İçmeden duramayacağınız, diğer bir deyişle vazgeçemeyeceğiniz sigara hangisidir?”
“a. Sabah içtiğim ilk sigara (1 puan) “
“b. Diğer herhangi biri (0 puan)”
“Soru 4: Günde kaç adet sigara içiyorsunuz?”
“a. 10 adet veya daha az (3 puan)”
“b. 11- 20 (2 puan)”
“c. 21- 30 (1 puan)”
“d. 31 veya daha fazlası (0 puan)”
“Soru 5: Sabah uyanmayı izleyen ilk saatlerde, günün diğer saatlerine göre daha sık sigara içer misiniz?”
“a. Evet (1 puan)”
“b. Hayır (0 puan)”
“Soru 6: Günün büyük bölümünü yatakta geçirmenize neden olacak kadar hasta olsanız bile sigara içer misiniz?”
“a. Evet (1 puan)”
“b. Hayır (0 puan)”
“Toplam skor”:
“0-2: Çok az bağımlılık”
“3-4: Az bağımlılık”
“5: Orta derecede bağımlılık”
“6-7: Yüksek bağımlılık “
“8-10: Çok yüksek bağımlılık”

2.2.4. Nikotin bağımlılığı Tedavisi

Nikotin bağımlılığının tedavisi, sigara bırakma tedavisi olarak bilinir. Nikotin tüketme dürtüsünü ve bununla ilişkili sağlık problemlerini azaltmayı amaçlar.

2.2.4.1. Davranış Tedavisi

Davranışsal danışmanlık, kişiye sigaradan kaçınmak ve nüksü önlemek için kullanabilecekleri başa çıkma ve problem çözme becerilerini öğretir. Aynı zamanda sosyal destek ve teşvik de sağlayabilir. Bir kişi danışmanlığa ne kadar çok zaman harcarsa, sigarayı kullanımını bırakma olasılığı o kadar artar (36).

2.2.4.2. Nikotin replasman tedavisi (NRT)

Nikotin bağımlılığını tedavi etmek için saf nikotin kullanılır. NRT ürünleri çeşitli formatlarda gelir: yama, sakız, pastil ve burun spreyi. Bazı formatlar diğerlerinden daha hızlı çalışır. Daha yavaş etki eden NRT'ler (yama), nikotin yoksunluğu semptomlarını azaltır. Daha hızlı etki eden NRT'ler (sakız, pastil, sprey) hem nikotin yoksunluk semptomlarını hem de istekleri azaltmak için daha erken çalışır. NRT ürünleri bir arada kullanılırsa daha etkili olabilir (37).

2.2.4.3. Bupropion

Nikotin bağımlılığını tedavi etmek için de reçete edilebilen bir antidepresandır. Nikotin bağımlılığında kilit rol oynayan noradrenerjik ve dopaminerjik etkilere sahiptir (38). Nikotin eksikliğinde artan dopamin aktivitesi, nucleus accumbens'te zevk verici bölgenin uyarılmasını destekler. Bupropion, noradrenalin ve dopaminin sinaptik geri emilimini zayıf bir şekilde inhibe ederek nikotin yoksunluk semptomlarını ortadan kaldırır. NRT ile aynı etkiye sahiptir (39, 40).

2.2.4.4. Vareniklin

Nikotin bağımlılığını tedavi etmek için kullanılan reçeteli bir ilaçtır. Nikotin yoksunluğunu ve isteklerini azaltmak için beyin üzerinde çalışır. Vareniklin, beyinde genellikle yalnızca nikotini taklit eden ve nikotine ihtiyaç duyan reseptörleri tetikler (41). Daha sonra reseptörler tarafından dopamin salınımını bloke eder ve beyindeki nikotine bağlı reseptörlerin sayısını azaltır. Bu da kişinin sigara içme isteğini azaltır. Aynı zamanda, Vareniklin, nikotinin beyinde salgılattığı bazı maddeleri kısmen salgılayabildiğinden, kişinin sigaradan duyduğu memnuniyeti de azaltabilir, bu da tekrarlama riskini azaltır. Vareniklin, tütün bırakmaya yönelik mevcut tedaviler arasında en yüksek bırakma oranına sahiptir (42, 43).

2.3. Lojistik Regresyon Analizi

Lojistik regresyon analizi, kategorik bir bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi açıklayan bir analiz yöntemidir. Lojistik regresyon analizi genellikle bağımlı değişkenin iki kategoriye sahip olduğu durumlarda kullanıldığı gibi ikiden fazla kategorili olduğu durumlarda tercih edilen bir analiz yöntemidir.

Lojistik regresyon analizinin temel amacı, bağımlı değişken ile bağımsız değişken arasında en az sayıda değişkene sahip ve modele en iyi uyan değişkenler arasındaki ilişkiyi belirleyebilen istatistiksel olarak anlamlı bir en uygun model oluşturmaktır (44, 45).

Çok değişkenli istatistik yöntemlerinden biri olan sınıflandırma, verilerin önceden tanımlanmış çıktılarına göre analiz edilmesini sağlayan bir yöntemdir. Sınıfların daha önce bilinen gruplar olması veya daha önce grupların bilinmemesi olarak iki grubun oluşturulduğu görülmektedir. Sınıflandırma yöntemleri de kendi içlerinde ikiye ayrılmaktadır. Sınıfların önceden bilinmemesi durumuna göre sınıflandırma işleminde çok boyutlu ölçekleme analizi veya kümeleme analizi kullanılırken, sınıfların önceden bilinmesi durumunda ise diskriminant analizi veya lojistik regresyon analizi kullanılmaktadır. Lojistik regresyon, kategorik hedef değişkenlerini analiz etmek için bir yöntem olarak diskriminant analizine alternatif bir yöntemdir. Birçok istatistikçi, lojistik regresyonun çok yönlü olduğunu ve zor problemleri modellemek için diskriminant analizinden daha uygun olduğunu düşünmektedir. Bunun nedeni, lojistik regresyonun, diskriminant analizinin yaptığı gibi, bağımsız değişkenlerin normal dağılım varsayımı gerektirmeyen bir yöntem olmasıdır. Lojistik regresyon analizi bağımlı değişkenin normal dağılması ve süreklilik varsayımları ön koşulu gerektirmeyen yapısı sayesinde en çok kullanılan analiz yöntemlerinden birisidir. (45, 46).

Son yıllarda lojistik regresyon askeri konularda, eğitim alanında kullanılmasının yanı sıra yaygın olarak tıp alanında sıklıkla kullanılan bir analiz yöntemidir. Tıp araştırmacıları çalışılan konuda fazla faktör varsa, faktörlerin bağımlı değişken üzerindeki etkisini tek tek araştırmak ve bu faktörlerin modele etkisini incelemek istemektedirler. Araştırmacı için bir diğer önemli soru, etkili olması beklenen faktörler ile hastalık arasındaki ilişkiyi risk açısından incelemektir. Bu tip çalışmalarda yaygın olarak Lojistik Regresyon yöntemi kullanılmaktadır (47).

2.3.1. Lojistik Regresyon Varsayımları

Lojistik regresyon, doğrusal regresyonun ve en küçük kareler algoritmalarına dayanan genel doğrusal modellerin temel varsayımların (normallik, varyansların homojenliği, doğrusallık ve ölçüm düzeyi) çoğunu yapmaz. Dolayısıyla daha esnek bir yapıya sahiptir. Lojistik regresyon analizi varsayımlar açısından daha esnek ve daha kullanışlı olmakla birlikte uygulanması için gerekli olan bazı özelliklere sahiptir.

Lojistik regresyon analizinin beş varsayımı vardır. Bu varsayımlar şunlardır (48):

1. Lojistik regresyon, bağımsız değişkenler arasında çoklu doğrusallığın olmadığını varsayar.
2. Lojistik regresyon, bağımsız değişkenlerle bağımlı değişkenin olasılık değeri arasında bir doğrusallık aranmaz.
3. Lojistik regresyon, doğru bir şekilde tahmin etmek için genellikle büyük bir örnekleme gerektirir.
4. Lojistik regresyon modelinin hata terimleri birbirinden bağımsızdır, hata terimleri arasında oto korelasyon yoktur.
5. Lojistik regresyon, gözlemlerin birbirinden bağımsız olduğunu varsayar.

2.3.2. Lojistik Regresyon Analizi Türleri

Lojistik regresyon, bağımlı değişkenin niteliğine bağlı olarak 3 temel yöntem içerir (38).

- i. İkili (iki şıklı- Binary) Lojistik Regresyon Analizi
- ii. Çoklu (ikiden çok şıklı) Sınıflayıcı (Nominal) Lojistik Regresyon Analizi
- iii. Çoklu (ikiden çok şıklı) Sıralayıcı (Ordinal) Lojistik Regresyon Analizi

2.3.2.1. İkili (Binary) Lojistik Regresyon Analizi

Bağımlı değişkenin iki kategoriye sahip olduğu modellerde ikili lojistik regresyon analizi kullanılmaktadır. Bağımlı değişken kodlanırken genellikle risksiz bir durum için sıfır (0) ve risk durumu için bir (1) kodu kullanılmaktadır. İkili lojistik regresyon modeli oluştururken bağımsız değişkenlerin türüne ilişkin herhangi bir kısıtlama yoktur. Bu bağlamda bağımsız değişkenler sürekli sayısal, kesikli sayısal, sırasız ya da sıralanabilir niteliksel değişken türleri olabilir (49).

Lojistik regresyon analizinde bağımlı değişkenin değerinin bilinmesi ile ilişkili değildir, sadece bağımlı değişkenin 1 değerini alma olasılığı bulunmasına çalışılır. Sonuç bir olasılık değeri olduğundan, bağımlı değişkenin olasılık değeri 0 ile 1 arasında değerler alır. Bu çalışmada, “ikili(binary) lojistik regresyon analizi” kullanılmıştır (50).

2.3.2.2. Çoklu Sınıflayıcı (Multinomial) Lojistik Regresyon Analizi

Çoklu sınıflayıcı lojistik regresyon analizi, bağımlı değişkenin ikiden fazla kategoriye sahip olduğu ve bu kategoriler arasında sıralama yapılmadığı durumlarda sıklıkla kullanılan analiz yöntemidir. Örneğin, sigara içmeye başlama nedenleri üzerine bir araştırma yapıldığında, bağımlı değişkenin üç seçenekten oluştuğunu varsayalım; merak, özentisi ve aile etkisi seçenekleri çoklu sınıflayıcı bir yapıya (multinomial) sahiptir. Böylece, bağımlı değişken ikiden fazla seçeneğe sahip olduğu durumlarda, çok seçenekli ve sıralamanın önemsiz olması nedeniyle de sınıflayıcı bir yapıya sahiptir (51).

2.3.2.3. Çoklu Sıralayıcı (Multiordinal) Lojistik Regresyon Analizi

Çoklu sıralayıcı lojistik regresyon analizi, bağımlı değişkenin ikiden fazla kategoriye sahip olduğu ve bu kategorilerin kendi aralarında “düşük”, “orta” ve “yüksek” gibi sıralandığı durumlarda yaygın olarak kullanılan analiz yöntemidir. Çoklu sıralayıcı lojistik regresyon analizinde, sıralı nitel değişkenler arasında sıralama işlemi olan paralellik varsayılır. Bu varsayım nedeniyle, β parametresi farklı kategoriler ve farklı kesme noktaları için farklı değildir. Bu nedenle, bu yöntem modeller arasında paralel doğru varsayımını test eder. Bu varsayım, çoklu sıralayıcı lojistik regresyon analizinin ana özelliğidir (52).

2.3.3. İki Kategorili (Binary) Lojistik Regresyon

Bağımlı değişkenin iki kategoriye sahip olduğu bir lojistik regresyon analiz yöntemleridir. Yukarıda bahsedildiği gibi kodlama yapılırken risksiz durum için 0 ve risk durum için 1 kodu kullanılır. Lojistik regresyon analizinde bağımlı değişkenin değerinin bilinmesi ile ilişkili değildir, sadece bağımlı değişkenin 1 olma olasılığı bilinmeye çalışılır. Sonuç bir olasılık değeri olduğundan bağımlı değişkenin olasılık değeri 0 ile 1 arasında değerler alır (48).


Yalnızca bir bağımsız değişkenin olması koşuluyla, model kurulumu üzerinde durulacaktır. Daha sonra, bağımsız değişkenlerin sayısı arttırılarak sınıflandırma ve oluşan modeli yorumlama üzerinde durulacaktır.

X =bağımsız değişken için veri matrisi olsun. $X=x$ olduğunda (X 'in değeri bilindiğinde) olayın olması olasılığı ya da $Y=1$ olması olasılığı π ile gösterilsin. π 'yi standart doğrusal model “Eşitlik 1” kullanılarak tanımlanır (49).

$$\pi(x) = P(Y = 1/X = x) = \beta_0 + \beta_1 x + \varepsilon \quad (\text{Eşitlik 1})$$

2.3.3.1. Lojit Model

Olasılık π ile X bağımsız değişkeni arasındaki ilişki, bağımlı değişkenin iki sonucu olduğunda lojistik fonksiyon S şeklinde gösterilir (49). İlk durumda X değerlerindeki artış olasılık π 'yi yavaşça artırır, sonra artış hızlanır ve sonunda durağanlaşmaya neden olur. Ancak fonksiyon 1'in üstüne çıkamaz. Böylesi bir grafiksel yapı, normal dağılımın birikimli olasılıklarının grafiklenmesi ile elde edilen grafiksel yapıya benzer ve bağımsız değişken(ler) ile olasılık arasındaki ilişki doğrusal olmaktan uzaktır (49, 53). Şekil 1'de lojistik fonksiyon grafiği gösterilmiştir.



Şekil 1. Lojistik fonksiyonu (Alpar'dan, 49)

Lojistik fonksiyonu tanımlayan lojistik regresyon modeli, Şekil 1'de gösterilen “Eşitlik 2” ile temsil edilmektedir. Bundan dolayı $X=x$ olduğunda $Y=1$ olma olasılığı π 'dir denir (45).

$$\pi(x) = P(Y = 1/X = x) = \frac{e^{(\beta_0 + \beta_1 x)}}{1 + e^{(\beta_0 + \beta_1 x)}} = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x)}} \quad (\text{Eşitlik 2})$$

İki kategorili bağımlı değişkenlerinin analiz etmek için çok çeşitli dağılım fonksiyonları literatürde mevcuttur. Lojistik regresyonun kullanılmasının üç temel sebebi (38):

- i. Fonksiyonun matematiksel açıdan daha esnek olması
- ii. Kullanım kolaylığı

iii. Sonuçların klinik açıdan anlamlı bir şekilde yorumlanabilmesi

Lojit dönüşümü, “Eşitlik 3” ile verilen doğrusal olmayan lojistik regresyon fonksiyonunun doğrusal olabilmesi için gerçekleştirilir. Lojit dönüşümü, bir olayın odds’unun doğal logaritması alınarak gerçekleştirilir. İlk olarak, bir olayın odds’u $p/(1-p)$ veya $\pi/(1-\pi)$ olarak temsil edilir ve bu oran 0 ile sonsuz (∞) arasında değer alabilir. Odds’ların doğal logaritması alındığında ise lojit dönüşüm yapılır. Sonuç olarak, bağımlı değişkenlerin sınırları $-\infty$ ile $+\infty$ arasında değer alabilir (49, 53).

$$Lojit\pi(x) = f(x) = \ln\left(\frac{\pi(x)}{1-\pi(x)}\right) \quad (\text{Eşitlik 3})$$

Lojistik regresyon modeli, bağımlı değişkenin odds’u türünden “Eşitlik 4” kullanılarak tanımlanır.


$$\frac{\pi(x)}{1-\pi(x)} = e^{(\beta_0 + \beta_1 x)} \quad (\text{Eşitlik 4})$$

Odds’un doğal logaritması alındığında model doğrulaşmış olur.

$$f(x) = \ln\left(\frac{\pi(x)}{1-\pi(x)}\right) = \ln e^{(\beta_0 + \beta_1 x)} = \beta_0 + \beta_1 x \quad (\text{Eşitlik 5})$$

“Eşitlik 5” ile ifade edildiği gibi, lojit dönüşümü β parametrelerinin doğrusal bir fonksiyonudur. Diğer bir deyişle lojit dönüşüm kullanıldığında, bağımsız değişkenler arasındaki ilişki doğrusal olması gerekmektedir. Lojistik regresyon model oluştururken tek varsayımı doğrusallıktır (49, 50).

Dönüştürülmüş model, olasılık değeri 0 ile 1 arasında artarken x ’in değerlerine bağlı olarak lojit $-\infty$ ile $+\infty$ arasında değerler almaktadır. Doğrusal modelde β_1 , x bağımsız değişkeninde 1 birimlik değişikliğin bağımlı değişkende ne kadar bir değişikliğe yol açtığını gösterirken, lojistik modelde, x ’teki 1 birimlik değişikliğin lojit’te ne kadar bir değişikliğe yol açtığını gösterir (44, 48). Şekil 2’de lojistik regresyon eğrisi gösterilmiştir.



Şekil 2. Lojistik regresyon eğrisi (Alpar’dan, 49)

Artık deęerler, doęrusal regresyonda 0 ortalama ve sabit varyansla normal daęılım gsterirken, lojistik regresyonda 0 ortalama ve $\pi(1 - \pi)$ varyansla binom daęılımı gsterirler (49).

2.3.3.2. Katsayıların Tahmini

Lojistik regresyon analizinde katsayı tahmini yapılırken sık kullanılan tahmin modeli en ok olabilirlik yntemidir. En ok olabilirlik ynteminde, denkleme ait parametreler iin deęerler gzlenen bir veri setinin olasılıęını en byk yapmaya dayalı olarak oluřturulur (48). Bu yntemi uygulamak iin ncelikle log olabilirlik adı verilen bir fonksiyonun oluřturulması gerekir. Oluřturulan fonksiyon, gzlenen verilerin olasılıęını denklemdaki parametrelerin bir fonksiyonu olarak tanımlar. Bu fonksiyonu maksimize eden deęerler, denklemdaki parametrelerin en ok olabilirlik tahmin edicileridir. zetle en ok olabilirlik ynteminde log olabilirlięi en byk yapılmaya alıřılır (49).

İstatistik yazılımların oęu lojistik regresyon modelinin katsayılarını tahmin etmek iin genellikle en ok olabilirlik yntemini tercih etmektedir. Bununla birlikte, model katsayıları, yinelemeli olmayan aęırlıklandırılmış en kk kareler ve diskriminant fonksiyon analizi yntemleri kullanılarak tahmin edilmektedir. rneklem byklę (n) arttıka, en ok olabilirlik ve aęırlıklandırılmış en kk kareler tahmin edicilerin daęılım zellikleri asimptotik olarak aynı olmaktadır. Diskriminant fonksiyon tahmin edicileri normal daęılım varsayımına duyarlıdır ve normal daęılım varsayımı saęlanmadıęında katsayıları olduęundan byk tahmin edebilir (49, 53).

En ok olabilirlik tahmin edicisi, rneklem byklę (n) sonsuza yaklařtıka tutarlı, yeterlidir ve asimptotik olarak normal daęılım zelliklerini gsterir. rneklem byklę yetersiz olduęunda bile en ok olabilirlik tahmin edicilerinin dřk performans gstermedięi literatrde belirtilmiřtir (45). Bu baęlamda deęiřken sayısından en az 10 kat daha fazla gzlem yapılması nerilmektedir. Bunun yanı sıra, baęımsız deęiřkenler arasında yksek oklu baęlantı ya da baęımlı deęiřkendeki deęiřkenlięin az olması (rneęin neredeyse tm deęerlerin aynı olması) durumunda rneklem byklęnn arttırılması nerilmektedir (49).

2.3.3.3. Katsayıların Anlamlılıęının Test Edilmesi

Lojistik regresyon katsayılarının tahminleri elde edildikten sonra, modeldeki deęiřkenlerin nemlilięi test edilmesi gerekmektedir. Baęımlı deęiřkenin modeldeki

bağımsız değişkenlerle arasındaki ilişkinin önemli olup olmadığı incelenir (50). Bir değişkeni içeren modelin, bağımlı değişken hakkında o değişkeni olmayan bir modele göre daha fazla bilgi içerip içermediği, bağımlı değişkenin katsayısı için anlamlılık testi yapılarak belirlenmiş olur. Bu yapmak için bağımlı değişkenin gözlenen değerleri, her iki model kullanılarak elde edilen tahmin değerleriyle karşılaştırılır. Değişken modele dahil edildiğinde, bu değişkenin daha iyi veya doğru tahminler elde etmek için önemli olduğuna karar verilmektedir (52). Modeldeki değişkenlerin önemliliği Olabilirlik oranı, Wald ya da Skor testleri olmak üzere üç yöntemden biri ile kontrol edilir.

Olabilirlik oran testi

Bağımsız değişkenin ikili veya çoklu lojistik regresyon modelinde, bağımsız değişkenlerin önemliliği olabilirlik oranı G istatistiği ile “Eşitlik 6” ile ifade edilmektedir (45).

$$LR = G = -2\ln\left(\frac{L(\text{değişken modelde olmadığında})}{L(\text{değişken modelde olduğunda})}\right) \quad (\text{Eşitlik 6})$$

LR asimptotik olarak ki-kare dağılımını gösterir. Serbestlik derecesi, iki modelde tahmin edilen değişken sayısı arasındaki farka eşittir. Olabilirlik oranı testi, sapma testi olarak da tanımlanabilir. Sapmanın doğrusal regresyondaki hatası, karelerin toplamına eşittir (49).

Modelde yalnızca bir bağımsız değişken olduğu göz önüne alındığında, başlangıçta modele sadece sabit terim dahil edilir. Sabit terim ve bağımsız değişken modele daha sonra alınır. Bu modellerden hesaplanan iki değer arasındaki fark -2 ile çarpılarak olabilirlik oranı test değeri hesaplanır (44, 49).

Hesaplanan test değerinin küçük olması, modele eklenen değişkenlerin logit’in tahmin edilmesinde önemli ölçüde katkıda bulunmadığını ve değişkenlerin modelde tutulmasına gerek duyulmadığını göstermektedir. Bu test işlemi modeli kurmak için örneklem büyüklüğü(n) yeterince büyük olduğunda geçerli olmaktadır (48, 49).

Wald testi

Wald testinde de olabilirlik oran testinde olduğu gibi beta katsayılarının en çok olabilirlik tahmin edicisi kullanılır. Wald testi, eğim parametresi β_1 ’in en çok olabilirlik tahmin edicisinin (β_j ya da b_j) standart hatasına ($S(\beta_j)$ ya da $S(b_j)$) bölünmesi ile

hesaplanır. “Eşitlik 7” ile ifade edilen Wald test istatistiği, $\beta_1 = 0$ hipotezi için standart normal dağılım gösterir (48, 50).

$$W = \frac{\beta_j}{s(\beta_j)} \quad (\text{Eşitlik 7})$$

“Eşitlik 8” ile ifade edilen Wald istatistiği β_1 ’in en çok olabilirlik tahmin edicisinin karesi standart hatasının karesine bölüldüğünde ki-kare dağılımı göstermektedir (49).

$$W^2 = \frac{\beta_j^2}{s(\beta_j)^2} \sim \chi^2 \quad (\text{Eşitlik 8})$$

Wald testinde büyük β_1 değerleri için standart hataların tahmininin arttırılmasından dolayı H_0 hipotezi yanlış iken reddedilmeyebilir. Bundan dolayı, model de değişken önemli olduğu halde önemsiz olarak kabul etme olasılığı artacak ve model için önemli olan değişken modelden çıkarılabilir (45, 47).

Skor testi

Skor testinde en çok olabilirlik tahmin edicilerinin hesaplanmasına gerek duyulmaz. Bu nedenle skor testinin en büyük avantajı hesaplama işlem sürecini kısaltmasıdır. Çok değişkenli bir test olan skor testi, matris hesaplamaları gerektirmektedir (49). Skor testi “Eşitlik 9”da ifade edilmiştir.

$$ST = \frac{\sum_{i=1}^n x_i(x_i - \bar{y})}{\sqrt{y_i(1 - \bar{y}) \sum_{i=1}^n (x_i - \bar{x})^2}} \quad (\text{Eşitlik 9})$$

Skor test istatistiği standart normal dağılım göstermektedir. SPSS gibi birçok istatistiksel yazılımlarda, adımsal yöntemlerde modele dahil edilecek veya modelden çıkarılması gereken bağımsız değişkenlerin belirlenmesi için testin çok daha kısa sürede hesaplanmasına olanak sağlaması avantajı ile tercih edilen bir testtir (49, 50).

2.3.4. Çoklu Lojistik Regresyon Analizi

Modelde iki veya daha fazla bağımsız değişken yer aldığında çoklu lojistik regresyon analizi kullanılmaktadır. Diğer bir deyişle çoklu lojistik regresyon analizi en basit şekilde ifade edilirse, tek değişkenli durumun genişletilmesi diyebiliriz (41). Bağımsız değişkenlerin sayısı p olmak üzere bağımsız değişkenler vektörü $x =$

$(x_1, x_2, \dots, x_p)$ ile tanımlanır. Bu vektörle çoklu lojistik regresyon denklemi “Eşitlik 10” ile gösterilir (49).

$$\pi(x) = P(Y = 1 | x) = \frac{e^{(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p)}}{1 + e^{(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p)}} = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p)}} \quad (\text{Eşitlik 10})$$

Lojistik regresyon modeli, bağımlı değişkeninin odds’u türünden “Eşitlik 11” ile gösterilir.

$$\frac{\pi(x)}{1 - \pi(x)} = e^{(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p)} \quad (\text{Eşitlik 11})$$

Odds’un doğal logaritması alınarak lojit dönüşüm yapıldığında “Eşitlik 12” elde edilir.

$$\text{lojit } \pi(x) = \ln\left(\frac{\pi(x)}{1 - \pi(x)}\right) \quad (\text{Eşitlik 12})$$

Odds’un doğal logaritması alındığında modelin doğrusal hale gelmiş olduğu “Eşitlik 13” bulunur.

$$g(x) = \ln\left(\frac{\pi(x)}{1 - \pi(x)}\right) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p \quad (\text{Eşitlik 13})$$

Çoklu lojistik regresyon analizi sonucunda model kurulduktan sonra, modeldeki her değişken için bir önemlilik testi yapılır. Tek değişkenli durumda olduğu gibi, olabilirlik oranı testi, modeldeki bağımsız değişkenler için modeldeki p adet β katsayısının sıfıra eşit olup olmadığını kontrol eder. Modeldeki β katsayılarının sıfırdan farklı olduğu sonucu bulunduğu Wald testi ile modeldeki değişkenlerin önemliliği test edilir (54). Çoklu lojistik regresyon analizinin amacı en az değişken ile en iyi uyuma sahip olacak modeli kurmaktır. Bu amaçla en iyi modeli kurmak için ileriye doğru ekleme ya da geriye doğru eleme gibi adımsal yöntemler kullanılır (55).

Çoklu lojistik regresyon yöntemi kullanılmadan önce bağımsız değişkenlerin, bağımlı değişken ile ki-kare, iki ortalama arasındaki farkın önemlilik testi, Mann-Whitney U testi gibi analizlerle incelenerek ilgisiz olanların modele alınmaması önerilmektedir (49, 55).

Bir diğer yaklaşım ise bağımlı değişkeni, her bir bağımsız değişkenle birlikte lojistik regresyon analizi kullanarak p değerini incelemektir. Yapılan analizler sonucunda p

değeri 0.25'in altında olan değerler modele katılması önerilmektedir. Böylece çok değişkenli analizden daha az değişken ile analiz yapılabilir (49, 54).

2.3.5. Lojistik Regresyon Analizinde Değişken Seçimi

Lojistik regresyon analizinde çok sayıda bağımsız değişken olması durumunda iyi bir model kurulması zorlaşmaktadır. Bu sebeple lojistik regresyon modeli kurulurken en az sayıda değişken veya faktör ile en iyi sonucu elde edebilecek en basit modeli oluşturmak gerekir. Modele dahil edilmesi veya hariç tutulması gereken değişkenler büyük önem taşımaktadır (52). Lojistik regresyon modellerinde bağımsız değişkenlerin tümünün her zaman bağımlı değişken üzerinde etkisi olmayabilir. Hatayı açıklayamayan değişkenlerin veya faktörlerin lojistik regresyon denkleminde tutularak modelin verimliliğinde ve tahmin gücünde bir azalmaya yol açar (53). Değişkenleri seçmek için kullanılan çeşitli yöntemler vardır. Bir model için değişken seçme yöntemleri arasında “standart (enter)” ve “adımsal (stepwise)” değişkenleri seçmeye yönelik iki ana yöntem yaygın olarak kullanılmaktadır. Adımsal yöntemlerde kendi içinde “ileri doğru seçim” (forward selection) ve “geriye doğru eliminasyon” (backward selection) olarak iki grupta ele alınır (56).

2.3.6. Model Uyum İyiliğinin İstatistikleri

Lojistik regresyon modelinin bağımlı değişkeni açıklamada ne kadar etkili olduğu uyum iyiliği testleri kullanılarak değerlendirilmektedir. Bir modelin veriye uyumunun iyi olup olmadığını belirlemek için geliştirilmiş çeşitli yöntemler kullanılarak araştırılabilir: Pearson ki-kare testi, sapma istatistikleri, Hosmer-Lemeshow testi, sınıflandırma tablosu ve işlem karakteristiği eğrisi (ROC eğrisi) altında kalan alan (55). Hosmer-Lemeshow testi risk tahmin modellerinde sıklıkla kullanılan bir testtir. Bu test yönteminde, olasılık değerlerine göre küçük büyüğe doğru sıralanır ve modeldeki verilerin yüzdelik değerlerine göre k gruba (k değeri genelde 10 olarak tercih edilir) ayrılır. Her biri grup için gözlenen ve beklenen frekanslar üzerinden test istatistiği hesaplanır. Test sonucu önemli çıkması durumunda modelin veriye uyumunun iyi olmadığı sonucuna varılır. Diğer bir deyişle iyi uyumlu bir model olması için p-değeri 0.05'ten büyük olmalıdır (57).

Modelin yeterliliğini belirlemek için açıklanan varyansı gösteren Nagelkerke R^2 değeri 0'dan 1'e bir değer almakta ve 1'e yaklaştıkça modelin açıklama gücünün arttığını göstermektedir. (54). Yapılan birçok çalışmada R^2 istatistiğinin oldukça küçük çıkma eğiliminde olması nedeniyle 0.20-0.40 arasındaki bir R^2 istatistiğinin yeterli olduğu sonucuna varılmıştır (57).

2.4. Yapay Zekâ

Zekâ, beynin öğrenme, anlama, soyut düşünme, akıl yürütme, planlama ve problem çözme gibi zihinsel işlevlerini ifade eder. Yapay zekâ, insanın düşünme yöntemlerini analiz ederek benzer yapay talimatları geliştirmeye çalışmaktır. Yapay zekâ (AI) terimi ilk olarak John McCarthy tarafından 1956'da İngiltere, New Hampshire'daki Dartmouth Koleji'nde düzenlenen bir konferansta ortaya çıktı. Bu konferansta yapay zekâ, akıllı makineler icat etme bilimi ve mühendisliği olarak tanımlanmıştır (58). AI, insan beyninin öğrenme özelliklerinden esinlenilerek, çevreyi algılayan ve başarı şansını artıran eylemler gerçekleştiren ve gelişimiyle de ilgilenen bir bilgisayar bilimi dalıdır (59). Yapay zekâ aşağıdaki şekilde de tanımlanabilir; farklı fikirleri aynı anda depolama ve işleyebilme yeteneği, geçmiş deneyimlerden öğrenme, karar verme mantığı, çıkarım gücü ve hızlı sonuca ulaşma özelliklerini içeren sistemler bütünüdür. Ayrıca, öncelikli özellikleri dikkate alarak kararlar verebilmeli ve karmaşıklık ve belirsizlikle başa çıkabilmelidir. Özet olarak AI, insan gibi fikir yürüten, insan gibi davranan, rasyonel düşünen, rasyonel davranış ve insan zekâsı gerektiren görevleri yerine getirmek için bilgisayar programları geliştirmekle ilgilenir. Günümüzde AI, sağlık sektörü başta olmak üzere spor müsabakaları, otomotiv ve askeri gibi birçok alanda kullanılmaktadır (1).

2.5. Makine Öğrenmesi (ML)

Makine öğrenimi (ML), yapay zekanın (AI) bir alt dalıdır. Makine öğreniminin amacı, genellikle verilerin yapısını anlamak ve bu verileri analiz ederek insanlar tarafından anlaşılır ve kullanılabilirliği sağlayan modeller üretilmesidir (60). Bilgisayar bilimi içinde bir alan olan makine öğrenmesi geleneksel hesaplama yöntemlerinden farklılık göstermektedir. Geleneksel hesaplamada kullanılan algoritmalar, hesaplamak veya problem çözmek için bilgisayarlar tarafından kullanılan açık bir şekilde programlanmış talimatların yerine getirilmesidir. Makine öğrenimi algoritmaları, bilgisayarların belirli bir aralık içerisinde bulunan değerleri tahmin etmek için girilen veriler üzerinde eğitim almasına ve istatistiksel analiz kullanılmasına izin verir. Bu nedenle, makine öğrenimi, veriye dayalı karar verme süreçlerini otomatikleştirmek için bilgisayarların geçmiş verilerden öğrenerek modeller üretmesine olanak tanır (2).

Günümüzde kullanılan birçok teknolojilerde makine öğreniminden yararlanılmıştır. Özellikle tıbbi teşhiste kullanılan makine öğrenmesi yüz tanıma, optik karakter tanıma (OCR) teknolojisi ve kullanıcı tercihlerine göre bir sonraki film veya televizyon


programlarının izlenmesi gibi birçok alanda hızla gelişmektedir (61). Makine öğrenmesinin performansını; kullanılan veri seti, veri setinde bulunan değişkenler, öğrenme stratejisi kullanılan algoritma olarak dört faktör etkilemektedir. Performans ne kadar yüksek olursa, sonuç yeni kişi için o kadar doğru olacaktır. Performans düşükse, makine öğrenimini etkileyen yukarıdaki faktörler değiştirilerek performansın optimize edilmesi önerilmektedir. Makine öğrenmesi üç grupta incelenmektedir (3). Danışmanlı öğrenme (supervised learning), danışmansız öğrenme (unsupervised learning) ve takviyeli öğrenme (reinforcement learning).

2.5.1. Danışmanlı Öğrenme (Supervised Learning)

Danışmanlı öğrenme, adından da anlaşılacağı gibi, öğretmen olarak bir denetçinin varlığına ihtiyaç duyulmaktadır. Temel olarak denetlenen öğrenim, makineyi iyi etiketlenmiş verileri kullanarak öğretilen veya eğitilen zamandır. Özet olarak denetimli öğrenme, veri setinde giriş değişkenleri (x) ve çıkış değişkenleri (Y) bulunduran ve girdi çıktı eşleştirme fonksiyonunu öğretmek için bir algoritma kullanılarak yapılan makine öğrenme yöntemlerinden biridir (1).” Eşitlik 14’de Y fonksiyonu tanımlanmıştır.

$$Y = f(x) \quad (\text{Eşitlik 14})$$

Sisteme yeni girdiler (x) eklendiğinde, girdi veriler için hedef değişkenlerini (Y) tahminde bulunmak amacıyla eşleştirme fonksiyonuna en iyi şekilde yaklaşmaktır. Buna danışmanlı öğrenme denir (61). Çünkü eğitim veri setinden öğrenen bir algoritma süreci, öğrenme sürecini denetleyen bir öğretmenin var olduğu düşünülür. Doğru çıktılar veri setinde bulunduğundan dolayı algoritma eğitim verilerinin üzerinden yinelemeli olarak tahminler yapılır ve öğretmen tarafından düzeltilir. Algoritma kabul gören bir performans değerine yaklaştığında öğrenme tamamlanır. Sınıflandırma ve regresyon problemleri danışmanlı öğrenmeye örnektir (3). Şekil 3’de danışmanlı öğrenme yöntemine ait sınıflandırma ve regresyon örneği verilmiştir.



Şekil 3. Sınıflandırma ve regresyon örneği (Goodfellow’dan, 3)

Aşağıda en çok kullanılan danışmanlı öğrenme yöntemleri verilmiştir. (62)

- Lojistik Regresyon (LR)
- Karar Ağaçları (KA)(DT)
- Yapay Sinir Ağları (YSA)
- En Yakın k Komşu Algoritması (KNN)
- Naive Bayes Sınıflandırma Algoritması (NB)
- Destek Vektör Makineleri (SVM)
- Rastgele Orman (RF)

Bu çalışmada danışmanlı öğrenme yöntemleri kullanılmıştır.

2.5.2. Danışmansız Öğrenme

Danışmansız öğrenme, sınıflandırılmamış veya etiketlenmemiş bilgileri kullanan ve algoritmanın rehberlik olmadan bu bilgilere göre hareket etmesine izin veren bir makine öğrenme yöntemidir. Burada makinenin görevi, önceden herhangi bir veri eğitimi almadan, sıralanmamış bilgileri benzerliklere, modellere ve farklılıklara göre gruplandırmaktır (2). Danışmansız öğrenme yöntemini kullanan öğrenme algoritmaları:

- Kümeleme
- Temel Bileşen Analizi
- Birlikte Kuralı Öğrenme

2.5.3. Takviyeli Öğrenme

Takviyeli öğrenme, bir dizi karar vermek için makine öğrenimi modellerinin eğitimidir. Temsilcinin, belirsiz, potansiyel olarak karmaşık bir ortamda bir hedefe ulaşması beklenir. Takviyeli öğrenmede, bir yapay zekâ oyun benzeri bir durumla karşı karşıya bırakılır. Yapay zekâ, soruna bir çözüm bulmak için deneme yanılma yöntemi kullanılır. Makinenin programcının istediğini yapmasını sağlamak için yapay zekâ, gerçekleştirdiği eylemler için ya ödül ya da ceza alır. Amacı, toplam ödülü maksimize etmektir (2).

2.5.4. Aşırı Öğrenme (Overfitting) ve Eksik Öğrenme (Underfitting)

Makine öğreniminde temel amaç eğitilen modelin, yalnızca eğitildiği veri kümesinde değil, aynı zamanda yeni bir veri kümesinde de iyi performans göstermesi beklenir. Yeni veriler modele katılarak modelin genelleme hata oranı hesaplanır ve bu oranın düşük olması iyi bir model olduğunu gösterir. Model eğitilme ve test edilme aşamalarında seçilen verilerin aynı olasılık dağılımına sahip veri setinden gelmesi gerekmektedir (2).

Makine öğrenmesinde kullanılan iki önemli kavram vardır: eğitim hatası ve test hatası (61).

- Eğitim Hatası: Bir modelin eğitim hatası modelin eğitildiği aynı veriler üzerinden hesaplanarak elde edilir.
- Test Hatası: Eğitilmiş modeli daha önce hiç maruz kalmadığı bir veri kümesi üzerinde çalıştırıldığında elde edilir.


Kurulan modelin iyi performans göstermesi için beklenen test hatasının, beklenen eğitim hatasından büyük veya eşit olması gerekmektedir. Kısaca, modelin kullanılabilir bir model olması için eğitim hatasının küçük olması ve eğitim-test hatasının arasındaki farkın az olması gerekmektedir (3).

Bir veri setinde bir sınıflandırıcı öğrenirken ortaya çıkabilecek eşit derecede sorunlu iki durum vardır. Bunlar eğitim setindeki verilerin bilinmeyen verilere uygulanmak üzere tahmin edilme derecesiyle ilgilidir:

Eksik Öğrenme: Eğitim setinden öğrenen sınıflandırıcı, model için sağlanan verileri hesaba katacak kadar açıklayıcı değildir. Bu durumda, sınıflandırıcı eğitim setinde bulunan ilgili bilgileri hesaba katmadığından hem eğitim hatası hem de test hatası yüksek olacaktır. Eksik öğrenme (Underfitting), model eğitim setinde yeterince düşük bir hata değeri elde edemediğinde gerçekleşir (2).

Aşırı öğrenme: Eğitim setinden öğrenen sınıflandırıcı modelin daha önce karşılaşmadığı veriler hakkında doğru çıkarımlar yapmak için kullanılamaz (3). Eğitim hatası zamanla azalmaya devam etse de sınıflandırıcı daha geniş bir dağılıma değil, yalnızca eğitim setinde var olan bilgilere dayalı kararlar almaya başladığında test hatası yeniden artmaya başlayacaktır. Aşırı öğrenme, eğitim hatası ile test hatası arasındaki boşluk çok büyük olduğunda meydana gelir (2).

Bu iki durumu ortadan kaldıracı için mevcut veri kümesini eğitim ve test veri setlerine böldükten sonra eğitim setinden, eğitim seti ve belirli bir yüzdesi doğrulama seti olarak ayrılıp modelin eğitimini gerçekleştirmesi gerekmektedir (3). Test sırasında modelin eğitiminden önce ayrılmış ve daha önce karşılaşmadığı veriler kullanılır. Doğrulama(validation), aşırı öğrenme problemini önlemek için yapılır. Doğrulamadan kaynaklanabilecek eksik öğrenme problemini önlemek amacıyla çapraz doğrulama(cross-validation) tekniği önerilmektedir (63). Buradaki amaç, modelin yüksek bir genelleme kabiliyetine sahip olması ve sadece mevcut test verileri üzerinde değil, diğer test verileri üzerinde de başarılı bir şekilde çalışmasını sağlamaktır (64). Aşırı öğrenme ve eksik öğrenmenin sorunlarını göstermek için test ve eğitim verilerinin tahmin hatası-model karmaşıklığına ilişkin grafik Şekil 4’te gösterilmiştir. Bu şekle göre eğitim verilerinin tahmin hatası azaldıkça test verilerindeki tahmin hatası artarsa aşırı öğrenme meydana gelmektedir. En uygun seviyede öğrenme sağlanmadan eğitim durdurulduğunda modelde eksik öğrenme oluşur. Modelin başarısını artırmak için en uygun öğrenme seviyesine ulaşılması gerekir (65). Aşırı öğrenme ve eksik öğrenme problemi Şekil 4’te gösterilmiştir.




Şekil 4. Aşırı öğrenme ve eksik öğrenme (Goodfellow’dan, 3)

2.5.5. Çapraz Doğrulama (Cross-Validation)

Çapraz doğrulama yönteminde, veri seti kullanıcı tarafından belirlenen k farklı alt kümelere bölünür ve defalarca eğitilir (61). Alt kümelere ayrıldıktan sonra her katmanda 1 birim doğrulama seti olurken, kalan k-1 birim eğitim seti olarak kullanılmaktadır. Eğitim sonunda tüm katmanların başarı oranlarının ortalaması alınarak elde edilen ortalama hata değeri modelin geçerliliğini göstermektedir. Çapraz doğrulama, modelin yüksek performansının rastgele olup olmadığını belirlemek için kullanılan bir doğrulama

yöntemidir. Bölünme sürecinden sonra, her birim Şekil 5'te gösterildiği gibi 5 kez ayrılarak eğitilmiş ve doğrulanmıştır (63).



Şekil 5. Çapraz doğrulama yöntemi ($k=5$)

Genellikle k değeri 3 veya 5 olarak seçilir. Bu değer 10 veya 15 olarak seçilebilir ancak bu çok pahalı bir hesaplama ve zaman kaybına neden olabilir. Çapraz doğrulama, aşırı öğrenme sorunu ile karşı karşıya olup olmadığının görülmesini ve ayrıca modelin kalitesini gösterir. Böylelikle henüz karşılaşmadığı test veri setinde yüksek hata oranları hesaplatılmadan modelin performansının test edilmesi sağlanır. Uygulanabilirliği kolay olduğu için sıklıkla tercih edilen bir yöntemdir. Bu yöntemin dışında Hold Out, Tekrarlı Hold Out, Tabakalı Öğrenme ve Üçlü Ayırma gibi başka yöntemler de vardır (66).

2.5.6. Yanlılık (Bias) ve Varyans


Makine öğrenimi algoritmaları doğal hataları olan matematiksel veya istatistiksel modeller kullanır. Bunlar indirgenebilir ve indirgenemez hata olmak üzere ikiye ayrılır. İndirgenemez hata veya doğal belirsizlik, bir sistem içindeki doğal değişkenlikten kaynaklanır. Karşılaştırıldığında indirgenebilir hata daha kolay kontrol edilebilen ve daha yüksek doğruluk sağlamak için en aza indirilmelidir (63).

Yanlılık ve varyans, indirgenebilir hatanın bileşenleridir. Modele ait genelleme hatasını azaltmak uygun karmaşıklığa ve esnekliğe sahip modellerin yanı sıra uygun eğitim verilerini seçmeyi gerektirir (64). Hatayı azaltmak ve doğru modeller oluşturmak için bias-varians dengesini sağlamak gerekmektedir. Yanlılık, eğitim setindeki modelin genelleme hatası ile tahmini hata oranı arasındaki farkı hesaplar. Yanlılık hatası, bir modelde kullanılan varsayımların basitleştirilmesinden kaynaklanır, böylece hedef işlemlere

yaklaşmak kolaylaşır ancak bu durum eksik öğrenmeye yol açmaktadır. Varyans, farklı eğitim verileri kullanılırsa hedef işlevin tahmininin ne kadar değişeceğini gösterir. Başka bir deyişle, varyans, rastgele bir değişkenin beklenen değerinden ne kadar farklı olduğunu açıklar (65). Yüksek düzeyde varyansa sahip bir model, hedef işlev yerine eğitim veri kümesindeki rastgele gürültüyü yansıtabilir. Bu durum aşırı öğrenmeye neden olabilir (67).

Genel olarak doğrusal makine öğrenme algoritmaları yüksek bias ve yüksek varyans değerine sahip olduğu bilinmektedir (63).

Yanlılık-varyans ikilemi, Şekil 6'da gösterildiği gibi ters orantılıdır. Danışmanlı bir makine öğrenimi algoritması oluştururken, en doğru tahminler için düşük bias ve varyans elde edilmesi önerilmektedir (3). Bias-Varyans dengesi Şekil 6'da gösterilmiştir.



Şekil 6. Bias-Varyans dengesi (Goodfellow'dan, 3)

2.5.7. Yeniden örneklendirme ve Sentetik veri artırma


Dengesiz bir veri kümesi, sınıfların eşit olmayan bir şekilde dağıldığı, yani her sınıf için yaklaşık olarak aynı miktarda veri olmadığı bir veri kümesidir. Yeniden örnekleme yapılarak dengesiz veri kümeleri daha dengeli bir hale getirilebilir. Yeniden örnekleme, orijinal veri örneklerinden çoğaltılmış örnekler oluşturmaya yönelik bir tekniktir. Yeniden örnekleme tekniği, parametrik olmayan bir istatistiksel çıkarım tekniğidir. Başka bir deyişle, yeniden örnekleme yöntemi, yaklaşık p-olasılık değerlerini hesaplamak için genel dağılım tablolarının (örneğin normal dağılım tabloları) kullanımını içermez. Yeniden örnekleme, orijinal veri örneğinden seçilen her bir örnek numarası için orijinal veri örneğine benzer birden çok durum olacak şekilde rastgele vakaların seçimini içerir. Değiştirme nedeniyle, yeniden örnekleme yöntemi kullanılarak alınan örneklerin sayısı tekrarlayan durumlardan oluşur (68).

2.6. Makine Öğrenmesi Algoritmaları (Sınıflandırıcılar)

Makine Öğrenmesi uygulamalarında etiketli verilerin sınıflandırılması için farklı algoritmalar geliştirilmiştir. Bu algoritmaların temelinde verilerin içerisinde gizlenmiş olan gizli örüntüyü ortaya çıkarmak amaçlanmıştır (69). Bu çalışmada LR, KA, KNN, RF, NB ve SVM algoritmaları kullanılmıştır.

2.6.1. Lojistik Regresyon (LR)

Lojistik Regresyon, bir ya da daha fazla bağımsız değişken arasındaki ilişkiyi ölçmek ve bir veri setini analiz etmek için kullanılan istatistiksel bir tekniktir. LR’de temel amaç, bağımlı değişken ile bir dizi bağımsız değişken arasındaki ilişkiyi tanımlamak için en az sayıda değişken ile en iyi uyuma sahip olacak şekilde oluşturabilecek en uygun modeli bulmaktır (70). Şekil 7’de lojistik regresyon sınıflandırıcıya bir örnek gösterilmiştir.



Şekil 7. Lojistik regresyon sınıflandırıcı

2.6.2. Karar Ağaçları (KA)

Karar ağaçları, adından da anlaşılacağı gibi kararın verilebilmesi için ağaç yapısı şeklinde basit bir sınıflandırma algoritmasıdır (64). Yüksek doğruluk, kararlılık, yorumlanma ve veri seti ile entegrasyon kolaylığı nedeniyle sınıflandırma problemlerinde yaygın olarak kullanılan bir yöntemdir. Karar ağaçlarında gerçek bir ağaç yapısına benzer dal, yaprak gibi bir takım özel terimler kullanılır (71). Bir karar ağacı, karar düğümleri ve yaprak düğümleri olmak üzere iki düğüm bulunmaktadır. Karar düğümleri, veri setinde karar vermek, sınıflandırmak veya tahmin etmek için kullanılan özneteliklerdir ve iki veya

daha fazla dala ayrılabilirler. Yaprak düğümlerde kararlar tutulur ve başka dallar içeremez. Ağacın en üst düğümü, kök düğüm olarak adlandırılır. Karar vermek için ağacın kökünden yaprak düğümlerine kadar belli bir yol izlenir (72). Kısaca, karar ağacı terminolojisi aşağıdaki terimlerden oluşmaktadır (71).

- “Kök Düğüm”: Tüm veri setini temsil eder ve bu düğüm daha sonra iki veya daha fazla kümeye bölünür.
- “Parçalama”: Bir düğümü iki veya daha fazla alt düğüme bölme işlemidir.
- “Karar Düğümü”: Bir alt düğüm diğer alt düğümlere bölünürse buna karar düğümü denir.
- “Yaprak Düğümü”: Bölünmeyen düğümlere denir.
- “Budama”: Karar düğümünden alt düğümleri çıkardığımızda bu işleme budama denir. Dolayısıyla parçalanma sürecinin tersini söyleyebiliriz.
- “Alt Ağaç”: Tüm ağacın bir alt bölümüne dal veya alt ağaç denir.
- “Ebeveyn ve Çocuk Düğümü”: Alt düğümlere bölünmüş bir düğüme, alt düğümlerin ebeveyn düğümü ve alt düğümleri de çocuk düğüm olarak adlandırılır.

Karar ağacı öğrenme, tümevarımsal çıkarım için sıklıkla tercih edilen yöntemlerden biridir. Amaç, verilerin özelliklerinden çıkarılan basit karar kurallarını öğrenerek bir hedef değişkenin değerini tahmin eden bir model üretmektir (72).

2.6.3. En Yakın k Komşu Algoritması (KNN)

K-en yakın komşular (KNN) algoritması, sınıflandırma ve regresyon problemlerini çözmek için kullanılabilen basit, uygulaması kolay, denetimli bir makine öğrenme algoritmasıdır. KNN, örüntü tanıma, metin madenciliği, ekonomi, tıp ve tarım gibi birçok farklı sorunun çözümünde uygulanabilir bir istatistiksel yöntemdir (73). KNN için veri seti ile ilgili daha önceden herhangi bir bilgiye ihtiyaç yoktur ve tüm veri seti bir örüntü uzayında tutulur. Veri setlerindeki örneklerin bağımsız ve eşit olarak paylaşıldığı varsayılır, bu nedenle birbirine benzeyen örneklerin benzer sınıflandırmaya sahip olduğu varsayılır (74).

Algoritma işleminde bir K değeri belirlenir. K değeri, bilinmeyen bir veri geldiğinde en yakın komşu eleman sayısıdır. Bilinmeyen bir veri geldiğinde, en yakın k kadar eleman alınarak, bilinmeyen veri ile en yakın komşu elemanlar arasında mesafe hesaplanır. Mesafe hesaplamak için genelde Öklid fonksiyonu tercih edilir. Öklid işlevine alternatif olarak Manhattan, Minkowski ve Hamming gibi farklı türden mesafe ölçümleri

de mevcuttur (73). Mesafe hesaplandıktan sonra sıralanır ve k adet veriden hangisine daha çok benziyorsa onun sınıfıyla etiketlenir (74).

Öklid fonksiyonu iki veri arasında “Eşitlik 15” formülüyle hesaplanır.

$$d(x, y) = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (\text{Eşitlik 15})$$

Bu algoritmanın en kritik noktası doğru k değerinin belirlenmesidir. Gözlem sayısının çok olduğu veri setinde k değerinin büyük seçilmesi önerilmektedir (75).

2.6.4. Rastgele Orman (RF)

RF, hiper-parametre ayarı olmadan bile genellikle yüksek doğruluk üreten esnek, hızlı ve kullanımı kolay bir makine öğrenimi algoritmasıdır (76). Çok sayıda karar ağacı oluşturarak sınıflandırma doğruluğunu iyileştirmeyi amaçlayan bir algoritmadır. Oluşturulan karar ağaçları birbirleri ile birleştirilerek çoklu karar ormanına dönüştürülür. Buradaki karar ağaçları birbirinden bağımsızdır ve rastgele seçilen her bir veri kümesinin bir alt kümesidir. Grup olarak çalışan bu algoritma, her ağacın tahminde bulunmasını sağlamaktadır. Bu tahminlerin sonucunda en çok oy alan sınıf modelin genel kararı olarak gösterilir. Sınıflandırma işleminde, her yaprak düğüm, yalnızca bir sınıfın üyelerini içerecek şekilde oluşturulur (77). RF, Bankacılık, Borsa, E-ticaret ve Tıp gibi birçok farklı alanda kullanılmaktadır. Sağlık alanında, tıp alanında faktörlerin doğru kombinasyonunu belirlemek ve hastalıkları teşhis etmek için hastanın tıbbi kayıtlarını analiz etmek için uygulanmaktadır (78).

RF algoritması için iki parametre tanımlanır (76).

- M= En iyi bölünmeyi belirlemek için her düğümde kullanılan değişkenlerin sayısı
- N= Oluşturulacak ağaç sayısı

Her düğümde tüm değişkenler arasından rastgele M değişkenleri seçilir ve bu değişkenler arasından en iyi dal belirlenir. M değişkenlerinin sayısı genellikle optimum sonuca en yakın olan sonucu verir. GINI indeksi, sınıfların homojenliğini ölçmek için hesaplanır. GINI indeksi ne kadar düşükse, sınıf o kadar homojendir. Bir alt düğümün GINI indeksi, bir üst düğümün GINI indeksinden daha az olduğunda, o dalın başarılı olduğu belirtilir (79). GINI indeksi “Eşitlik 16” formülüyle hesaplanır.

$$GINI(T) = 1 - \sum_{j=1}^c (p_j)^2 \quad (\text{Eşitlik 16})$$

T= Tüm veri seti

p_j = Veri setindeki her bir verinin kendisinden küçük ve kendisinden büyük eleman sayılarına bölüm karesi

c= Toplam sınıf sayısı

GINI indeksi belirlendikten sonra, test veri setlerimiz GINI indeksine göre sınıflandırılır. Elde edilen sonuçlara göre en uygun sınıflandırma yapılır (79).

2.6.5. Naive Bayes (NB)

Naive Bayes sınıflandırıcı, veri kümesindeki özelliklerin birbirinden bağımsız olmasını varsayan ve sınıflandırma görevi için kullanılan olasılığa dayalı bir makine öğrenimi modelidir. Bu varsayım sonucunda belirli bir özelliğin varlığı diğerini etkilemez. Dolayısıyla naif denir. Sınıflandırıcının püf noktası Bayes teoremine dayanmaktadır. Bir değer gerçeğe olasılığı koşullu olasılık yardımıyla hesaplanır. Bunun sonucunda, hedef sınıfın değeri tahmin edilir. Bayes Teoremi “Eşitlik 17” kullanılarak hesaplanır (80).

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (\text{Eşitlik 17})$$

- A: Tahmin edilmeye çalışılan sınıf.
- B: Tahmin edilen sınıf.
- $P(A|B)$: B olayı olduğunda, A olayının gerçekleşmesidir.
- $P(B|A)$: A olayı olduğunda, B olayının gerçekleşmesidir.
- $P(A)$: A olayının olma olasılığı
- $P(B)$: B olayının olma olasılığı

Bayes teoremi “Eşitlik 18” kullanılarak ifade edilebilir:

$$P(y|X) = \frac{P(X|y)P(y)}{P(X)} \quad (\text{Eşitlik 18})$$

X verideki özellikleri y’de sınıf değerini gösterebilir (“Eşitlik 19”).

$$X = (x_1, x_2, x_3, \dots, x_n) \quad (\text{Eşitlik 19})$$

$$P(y|x_1, \dots, x_n) = \frac{P(x_1|y)P(x_2|y)\dots P(x_n|y)P(y)}{P(x_1)P(x_2)\dots P(x_n)} \quad (\text{Eşitlik 20})$$

“Eşitlik 20” de ifade edilen veri kümesinde her bir özellik için değerler elde edilir ve bunlar denkleme yerleştirilir. Veri kümesindeki her bir giriş için payda değişmez, sabit kalır. Bu nedenle payda kaldırılır “Eşitlik 21” elde edilir.

$$P(y|x_1, \dots, x_n) \propto P(y) \prod_{i=1}^n P(x_i|y) \quad (\text{Eşitlik 21})$$

Sınıflandırma işlemi maksimum olasılıkla hesaplanmalıdır.


$$y = \underset{y}{\operatorname{argmax}} P(y) \prod_{i=1}^n P(x_i|y) \quad (\text{Eşitlik 22})$$

“Eşitlik 22” de elde edilen formül yardımıyla giriş özellikleri verildiğinde hangi sınıfa ait olduğu tahmin edilebilir.

NB algoritması hızlı ve kolaydır, ancak en büyük dezavantajı, özniteliklerin bağımsız olması varsayımdır. Gerçek hayat problemlerinde, öznitelikler birbirleriyle ilişkilidir bu nedenle sınıflandırıcının performansını etkileyebilir (81).


2.6.6. Destek Vektör Makineleri (SVM)

SVM, değişkenler arasındaki örüntülerin bilinmediği veri kümelerindeki sınıflandırma problemleri için önerilen bir makine öğrenme yöntemidir. Doğrusal olmayan, yerel minimum ve yüksek boyut gibi problemleri çözmek için uygulanmaktadır. Yapısal risk minimizasyonu (SRM) prensibi, SVM'nin temelini oluşturur. SVM temel amaç, farklı sınıfların veri noktaları arasında doğru bir şekilde sınıflandırmak için en uygun bir ayırma çizgisi veya bir hiper düzlemi bulmaktır (82). SVM algoritmasının altındaki temel fikir, veri noktalarını açıkça sınıflandıran N boyutlu bir alana (N özellik sayısıdır) sahip bir karar düzlemi oluşturmaktır (83).



Şekil 8. En uygun hiper düzlem (Vapnik'ten, 82)

Her iki sınıfın noktaları için çizgiyi maksimum mesafede tutmayı amaçlamaktadır.



Şekil 9. Destek vektörleri (Xuegong'dan, 83)

Şekil 9'da siyahlar ve beyazlar olmak üzere iki farklı sınıf vardır. Sınıflandırma problemlerinde temel amaç, daha önce bilinmeyen verilerin hangi sınıfa dahil edileceğine karar vermektir. Bu sınıflandırmayı yapmak için iki sınıfı ayıran bir çizgi çekilir ve bu çizginin ± 1 arasındaki yeşil alana Margin denir. Margin ne kadar genişse, iki veya daha fazla sınıfın ayrılması o kadar iyi olur (83).

Destek vektör makineleri iki sınıflı sınıflandırma işleminde, $i = 1, \dots, N$ e kadar (x_i, y_i) için $x_i \in R^d$ olmak üzere y_i değerleri $\{-1, +1\}$ şeklinde sınıf etiketleri olarak değer alır. Eğitim verileri ile elde edilen bir karar fonksiyonu yardımıyla gösterilen iki sınıfa ait örneklerin birbirinden ayrılması amaçlanmaktadır. Sınıflandırma formülü “Eşitlik 23” ile ifade edilebilir (84).

$$f(x_i) = \begin{cases} w^T x + b < 0, & y_i = -1 \\ w^T x + b \geq 0, & y_i = +1 \end{cases} \quad (\text{Eşitlik 23})$$

- w =Ağırlık vektörü
- x =girdi vektörü
- b =sapma
- y =tahmin edilecek sınıf

Şekil 9 için, yeni bir değer sonucunu 0'dan küçükse, beyaz noktalara daha yakın olacaktır. Tersine, sonuç 0'dan büyük veya 0'a eşitse, siyah noktalara daha yakın olacaktır (83, 84).

2.7. Yapay Sinir Ağları (YSA)

Yapay sinir ağları (YSA), insan beyninin bilgiyi analiz etme ve işleme şeklini taklit ederek mevcut verileri analiz eden ve bu verilerden farklı öğrenme algoritmaları ile yeni bilgiler oluşturan yapay zekâ yöntemlerinden biridir (85). Yapay sinir ağları, insan beyin yapısını kullanarak öğrenme sürecinin matematiksel olarak modellenmesi sonucunda ortaya çıkmıştır. Beyindeki biyolojik sinir ağlarının yapısını, öğrenme, hatırlama ve genelleme yeteneklerini taklit eder. Öğrenme sırasında girdi ve çıktı bilgileri verilerek kurallar belirlenir (86).

2.7.1. Yapay Sinir Ağlarının Avantajları

Yapay sinir ağları yönteminin bazı avantajları vardır (85).

- Yapay Sinir Ağları birçok hücreden oluşur ve bu hücreler eş zamanlı çalışarak karmaşık görevleri yerine getirir.
- Farklı öğrenme algoritmaları ile öğrenme yeteneğine sahiptirler.
- Verilere dayanarak bilinmeyen ilişkileri ortaya çıkarabilir ve daha önce karşılaşmadığı veriler için sonuçlar (bilgi) üretebilirler.
- Örüntü tanıma ve sınıflandırma yapabilirler.
- Hata toleransları vardır. Eksik veya belirsiz bilgilerle çalışabilirler. Hatalı durumlarda, dereceli bozulma gösterirler.
- Paralel olarak çalışabilir ve eş zamanlı bilgileri işleyebilirler.

2.7.2. Yapay Sinir Ağlarının Kullanım Alanları

Yapay sinir ağları çoğunlukla teşhis, sınıflandırma, tahmin, kontrol, veri ilişkilendirme, veri filtreleme ve yorumlama gibi birçok farklı alanlarda kullanılmaktadır (87).

- Hesaplamalı finans: kredi puanlama, algoritmik ticaret gibi finansın birçok alanında kullanılmaktadır.
- Görüntü işleme ve bilgisayarla görme: yüz tanıma, hareket algılama, nesne algılama gibi tespit etme problemlerinde tercih edilmektedir.
- Hesaplamalı biyoloji: Tümör tespiti, ilaç keşfi (ilaç keşfi), DNA sekanslama (DNA sekanslama) gibi biyoloji ve biyoenformatik ile ilgili birçok alanda sıklıkla kullanılmaktadır.
- Enerji üretimi: Fiyat ve yük tahmini yapmak için enerji alanında tercih edilmektedir.

- Otomotiv, havacılık ve üretim (Otomotiv, havacılık ve üretim): Öngörücü bakım yapmak için otomotiv sektöründe kullanılmaktadır.
- Doğal dil işleme: Sesli asistan, Duygu analizi gibi son yıllarda doğal dil işleme problemleri arasında sıklıkla kullanılmaktadır.

2.7.3. Geleneksel Algoritmalar ile YSA'ların Karşılaştırılması


Tablo 4’de Geleneksel algoritmalar ile YSA’ların karşılaştırılması gösterilmiştir.

Tablo 4. Geleneksel algoritmalar ile YSA’ların karşılaştırılması (Pirim’den, 88)

“Geleneksel Algoritmalar”	“Yapay Sinir Ağları”
“Sonuçlar, girdilerin belirlenen kurallara uygulanmasıyla elde edilir.”	“Kurallar, öğrenme sırasında girdi ve çıktı bilgisi verilerek belirlenir.”
“Hesaplama; merkezi, eşzamanlı ve sıralıdır.”	“Hesaplama; toplu, eş zamansız ve öğrenmeden sonra paraleldir.”
“Bellek paketlenmiş ve hazır bilgi depolanmıştır.”	“Bellek ayrılmış ve ağı yayılmıştır.”
“Hata toleransı yoktur.”	“Hata toleransı vardır.”
“Nispeten hızlıdır.”	“Yavaş ve donanıma bağımlıdır.”
“Bilgiler ve algoritmalar kesindir.”	“Deneyimden yararlanır.”

2.7.4. Biyolojik Sinir Hücresi

Biyolojik Sinir Sistemi; Sinirlerin taşıdığı bilgileri yorumlayarak uygun kararlar veren beyin odaklı bir sistemdir. Biyolojik sinir sistemindeki temel yapı ve işlev birimi, nöron adı verilen sinir hücreleridir. Nöronlar bilgiyi taşıma ve işleme yeteneğine sahiptir. Her nöron kendisinden önceki nörondan bilgiyi taşıyarak fonksiyonlar oluşturur. Biyolojik sinir hücresinin temel unsurları, Dendritler (Dendrit), Hücre Gövdesi (Soma), Aksonlar (Akson) ve Sinapslardan (Sinaps) oluşur (89). YSA, biyolojik sinir ağlarının işlevselliğini ve yapısını taklit etmeyi amaçlayan matematiksel modellemenin bir sonucu olarak ortaya çıkmıştır (86). Şekil 10’da biyolojik sinir hücresinin yapısı gösterilmiştir.



Şekil 10. Biyolojik sinir hücresinin yapısı (Bulut’tan, 89)


Diğer sinir hücrelerinden sinir hücresine gönderilen uyarılar, hücre gövdesine dendritler yoluyla taşınır ve hücre içi aktivasyon / kararlı durum bozulmasının neden olduğu kimyasal bir süreçte aksonlar tarafından diğer hücelere iletilir; Akson uçları ve dendritler arasındaki sinaptik boşluklar (sinapslar), uyarıların diğer sinir hücrelerine iletilmesinde rol oynar (87). Sinaptik boşlukta bulunan "sinaptik veziküller", gelen dürtülerin dendritler yoluyla diğer hücelere geçmesini şartlandıran unsurlardır. "Sinaptik veziküller" tarafından sağlanan nöro-iletken malzemenin sinaptik boşluğa doldurulması, uyarıların diğer hücelere geçişini koşullandırır. Hücreler arasında var olan sinaptik ilişkilerin değişmesi veya hücelere gelen uyarılara göre hücreler arasında yeni sinaptik ilişkilerin kurulması "öğrenme" sürecine tekabül etmektedir (90). Biyolojik sinir yapısının terimlerine karşılık gelen yapay sinir ağındaki terimler Tablo 5'te gösterilmiştir.

Tablo 5. Biyolojik Sinir Yapısı ile Yapay Sinir Ağı karşılıkları (Koç'dan, 90)

"Biyolojik Sinir Sistemi"	"Yapay Sinir Sistemi"
"Nöron"	"İşlemci eleman"
"Dendrit"	"Toplama fonksiyonu"
"Hücre gövdesi"	"Transfer fonksiyonu"
"Aksonlar"	"Yapay nöron çıkışı"
"Sinapslar"	"Ağırlıklar"

2.7.5. Yapay Sinir Hücresinin Yapısı

Yapay sinir hücresi, Şekil 10'da gösterildiği gibi biyolojik sinir hücrelerine benzer yapıdadır. Bu ağlar biyolojik bir sinir ağından ilham alır, ancak biyolojik sinir sistemlerinden daha az kavram kullanır (91). Yapay nöronlar, aralarında bir bağlantı oluşturularak yapay sinir ağlarını oluştururlar. Tıpkı biyolojik nöronlar gibi, yapay nöronların da giriş sinyallerini aldıkları, bu sinyalleri toplayıp işledikleri ve çıktıları ilettikleri bölümleri vardır (92). Şekil 11'de yapay bir sinir ağının yapısı gösterilmektedir. Yapay bir sinir hücresi beş temel elemandan oluşmaktadır (93). Bunlar; "Girdiler", "Ağırlıklar", "Toplama Fonksiyonu(Birleştirme Fonksiyonu)", "Aktivasyon Fonksiyonu" ve "Çıktılar" olarak adlandırılır.



Şekil 11. Yapay sinir ağı örneği (Goodfellow'dan, 3)

Girdiler: Girdiler, başka bir hücreden veya doğrudan dış dünyadan nöronlara gelen bilgilerdir (91).

Ağırlıklar: Yapay nörona ulaşan bilgiler, girişler vasıtasıyla çekirdeğe ulaşmadan önce bağlantıların ağırlığı ile çarpılarak çekirdeğe iletilir. Böylece girdilerin çıktı değerleri üzerindeki etkileri ayarlanabilir (91, 93).





Toplama Fonksiyonu (Birleştirme Fonksiyonu): Toplama fonksiyonu, hücreye gelen girdiler ile o girdilerin ağırlıklarının çarpılarak toplanmasıdır. Yapay bir sinir hücresinin net girdisini hesaplayan bir fonksiyondur (91, 93). Bazı toplama fonksiyonları Tablo 6'da gösterilmiştir.

Tablo 6. Bazı toplama fonksiyonları (Çayıroğlu'dan, 91)

Toplam $NET = \sum_{i=1}^N X_i * W_i$	Ağırlık değerleri hücreye gelen girdilerle çarpılır. Net girdi, çarpma sonucu elde edilen değerler toplanarak hesaplanır.
Çarpım $NET = \prod_{i=1}^N X_i * W_i$	Ağırlık, hücreye gelen girdilerle çarpılır. Çarpım sonucu elde edilen değerler birbiriyle çarpılarak net girdi hesaplanır.
Maksimum $NET = \text{Max}(X_i * W_i)$	Ağırlıklar, N adet girdilerle çarpıldıktan sonra en büyüğü Net girdi olarak kabul edilir.
Minimum $NET = \text{Min}(X_i * W_i)$	Ağırlıklar girişlerle çarpıldıktan sonra, N adet girişten en küçüğü net giriş olarak kabul edilir.
Çoğunluk $Net = \sum_{i=1}^N \text{Sgn}(X_i * W_i)$	N adet girdi içinden ağırlıklar girdilerle çarpıldıktan sonra pozitif ile negatif olanların sayısı bulunur. İşarete bakılmaksızın büyük olan sayı hücrenin net girdisi olarak kabul edilir.
Kümülatif Toplam $Net = Net(eski) + \sum_{i=1}^N X_i * W_i$	Hücreye gelen bilgiler ağırlıklı olarak toplanır ve önceki bilgiler ile yeni hesaplanan giriş değerleri eklenerek hücreye net giriş hesaplanır.

Aktivasyon Fonksiyonu: Bu, bir hücrenin girdisini işleyen ve daha sonra bir çıktı oluşturan ve onu bir sonraki katmana geçiren bir fonksiyondur (93). Aktivasyon fonksiyonu türleri Tablo 7’de gösterilmiştir.


Tablo 7. Aktivasyon fonksiyonu türleri (Çayıroğlu’dan, 91)

Doğrusal (Lineer) Aktivasyon Fonksiyonu		$F(Net) = A * Net$ (A sabit bir sayı)	Doğrusal problemler çözmek amacıyla aktivasyon fonksiyonu doğrusal bir fonksiyon olarak seçilebilir. Toplama fonksiyonundan çıkan sonuç, belli bir katsayı ile çarpılarak hücrenin çıktısı olarak hesaplanır.
Adım (Step) Aktivasyon Fonksiyonu		$F(Net) = \begin{cases} 1 & \text{if } Net > \text{Eşik Değer} \\ 0 & \text{if } Net \leq \text{Eşik Değer} \end{cases}$	Gelen Net girdinin belirlenen bir eşik değerin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerini alır.
Sigmoid Aktivasyon Fonksiyonu		$F(Net) = \frac{1}{1 + e^{-Net}}$	Sigmoid aktivasyon fonksiyonu sürekli ve türevi alınabilir bir fonksiyondur. Doğrusal olmayışı dolayısıyla yapay sinir ağı uygulamalarında en sık kullanılan fonksiyondur. Bu fonksiyon girdi değerlerinin her biri için 0 ile 1 arasında bir değer üretir.
Tanjant Hiperbolik Aktivasyon Fonksiyonu		$F(Net) = \frac{e^{Net} + e^{-Net}}{e^{Net} - e^{-Net}}$	Tanjant hiperbolik fonksiyonu, sigmoid fonksiyonuna benzer bir fonksiyondur. Sigmoid fonksiyonunda çıkış değerleri 0 ile 1 arasında değişirken hiperbolik tanjant fonksiyonunun çıkış değerleri -1 ile 1 arasında değişmektedir.
Eşik Değer Fonksiyonu		$F(Net) = \begin{cases} 0 & \text{if } Net \leq 0 \\ Net & \text{if } 0 < Net < 1 \\ 1 & \text{if } Net \geq 1 \end{cases}$	Gelen bilgilerin 0 dan küçük-eşit olduğunda 0 çıktısı, 1 den büyük-eşit olduğunda 1 çıktısı, 0 ile 1 arasında olduğunda ise yine kendisini veren çıktılar üretilebilir.
Sinüs Aktivasyon Fonksiyonu		$F(Net) = \sin(Net)$	Öğrenilmesi düşünülen olayların sinüs fonksiyonuna uygun dağılım gösterdiği durumlarda kullanılır.

Çıktılar: Aktivasyon fonksiyonu tarafından üretilen değerlerdir (93).

2.7.6. Yapay Sinir Ağlarının Yapısı

Yapay sinir ağları, yapay sinir hücrelerindeki nöronların birbirine bağlanmasıyla oluşan graf yapılarıdır. Yapay sinir ağları, Giriş Katmanı, Ara (Gizli) Katmanlar ve Çıkış Katmanı olmak üç ana katmandan oluşur (85). Şekil 12’de yapay sinir ağının yapısı gösterilmiştir.



Şekil 12. Yapay sinir ağının yapısı (Çayıroğlu'dan, 91)

Giriş Katmanı: Sisteme giriş olarak gelen bilgiler bu katmanda yer alır. Bu katmanda giriş düğümlerinde hesaplama yapılmaz yalnızca bilgileri gizli düğümlere iletirler (85).

Gizli (Ara) Katman(lar): Gizli düğümlerin dış dünyayla doğrudan bir bağlantısı yoktur (bu nedenle "gizli" adı da buradan gelir). Hesaplamalar yaparlar ve bilgileri giriş düğümlerinden çıkış düğümlerine aktarırlar. Öğrenme bu katmanda gerçekleşir. Yapay sinir ağlarında yapının kaç tane gizli katmandan oluşacağı veya kaç nöronla birleşeceği gibi kesin bir sayı kuralı yoktur. Spesifik bir formül olmadığı için ağ yapısının oluşturulması deneme yanılma yoluyla belirlenmelidir. Literatürde büyük veriler için genellikle bir veya iki gizli katmanın kullanılmasının yeterli olduğu öne sürülmüştür (86).

Çıktı Katmanı: Sistemin giriş verilerine göre öğrenilmesi gereken gizli katmanlardan iletilen bilgileri işleyerek ağın sonuçlarını veren katmandır (91).


2.7.7. Yapay Sinir Ağlarının Sınıflandırılması

Yapay sinir ağları, nöronların birbirine bağlanma yapısına göre ileri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağları olarak ikiye ayrılır (85).

2.7.7.1. İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli sinir ağlarında nöronlar arasında hiyerarşik bir yapı vardır. Bilgileri girişten çıkışa düzenli katmanlardan geçirir. Yapay sinir ağına gelen bilgi, gizli ve çıktı katmanlarında fonksiyonlarla belli bir ağırlığa sahip olur ve çıktı katmanından işlenerek geçer ve sonuç üretilir (86). Bir katmandaki nöronlar yalnızca bir sonraki katmana veri aktarabilir. Bir katmandaki her birim, bir önceki katmandaki tüm birimlerle bağlantılıdır. Bu bağlantıların hepsi eşit değildir: her bağlantının farklı bir gücü veya ağırlığı olabilir.

Katmanlar arasında geri bildirim yoktur. Bu yüzden ileri beslemeli sinir ağı olarak adlandırılır (91). Şekil 13'te ileri beslemeli çok katmanlı sinir ağının yapısı verilmiştir.




Şekil 13. İleri beslemeli çok katmanlı sinir ağının yapısı (Çayıroğlu'dan, 91)

Aşağıda iki ileri beslemeli ağ örneği verilmiştir (92):

1. Tek Katmanlı Algılayıcı (Single Layer Perceptron): Gizli katmanları olmayan en basit ileri beslemeli sinir ağıdır.
2. Çok Katmanlı Algılayıcı (Multi Layer Perceptron): Bir veya daha fazla gizli katmanı vardır. Bu tez çalışmasında çok katmanlı algılayıcı kullanılmıştır.

Çok Katmanlı Algılayıcı (MLP)


MLP, bilgilerin giriş katmanından girildiği ve gizli katman ya da katmanlardan çıktı katmanına tek yönde yayıldığı bir ileri beslemeli YSA'dır (92). Tek katmanlı bir algılayıcı yalnızca doğrusal işlevleri öğrenebilirken, çok katmanlı bir algılayıcı doğrusal olmayan işlevleri de öğrenebilir. Gizli ve çıktı katmanlar, algılayıcılar adı verilen tek birimlerden oluşur (93). MLP'deki her algılayıcı, önce ağırlıklandırılan ve sonra birbirine eklenen bir dizi girdi alır. Ortaya çıkan değer, birleştirilmiş girişleri uygun bir çıkış yanıtıyla eşleştirecek bir aktivasyon fonksiyonu kullanılır. MLP, eğitim için geri yayılma adı verilen denetimli bir öğrenme tekniğini kullanır. MLP, hatayı ağa yaydığı için "Geri Yayılma Modeli" veya "Hata Yayılma Modeli" olarak adlandırılır (94). Şekil 14'te çok katmanlı ağların yapısı verilmiştir.



Şekil 14. Çok katmanlı ağların yapısı (Krenker'dan, 92)

2.7.7.2. Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli yapay sinir ağlarında ileri beslemeli olanların aksine bir nöron kendinden sonraki katmana bilgi akışı gerçekleştirebildiği gibi kendinden önceki katmana veya kendi katmanına da bilgi aktarabilir. Bu yapı nedeniyle geri beslemeli yapay sinir ağları doğrusal olmayan dinamik bir davranış gösterir (92). Şekil 15'te geri beslemeli YSA yapısı gösterilmiştir.




Şekil 15. Geri beslemeli YSA (Krenker'dan, 92)

2.8. Derin Öğrenme (DL)

2.8.1. Derin Öğrenmeye Giriş

Derin öğrenme, veri işleme ve karar vermede kullanılmak üzere kalıplar oluşturmada insan beyninin işleyişini taklit eden bir yapay zekâ (AI) yöntemlerinden biridir. Derin öğrenme; nesne tanıma, konuşma tanıma, doğal dil işleme gibi alanlarda çok katmanlı yapay sinir ağlarını kullanan makine öğreniminin bir alt dalıdır. Derin sinir

öğrenme veya derin sinir ağı olarak da bilinir (3). Şekil 16’da derin öğrenme hiyerarşisi gösterilmiştir.




Şekil 16.Derin öğrenme hiyerarşisi (Goodfellow’dan, 3)

Derin öğrenme (ayrıca derin yapılandırılmış öğrenme, hiyerarşik öğrenme veya derin makine öğrenimi), yapay sinir ağlarının ve bir veya daha fazla gizli katmandan oluşan benzer makine öğrenimi algoritma yöntemlerinin bir oluşumdur. Derin öğrenme, insan beynindeki biyolojik nöronların hesaplama modellerinden ve çalışma prensibinden ilham alır. Bu bağlamda biyolojik nöronlar arasındaki bağlantıları ve karmaşık etkileşimleri yapay olarak taklit etmeye çalışır. Derin öğrenmeyi kullanmanın temel nedenlerinden biri, nöronların eşsiz ve bağımsız öğrenme yetenekleri sayesinde her türlü veriye uygulanabilmesidir. Bilgisayarların bilgi işlem donanımı geliştikçe gerçek dünyadaki problemlerle (kümeleme, sınıflandırma veya regresyon gibi) başa çıkmak için daha derin modeller doğrultusunda hareket eder (94).

2.8.2. Derin Öğrenme Tarihçesi

1965'te “Ivakhnenko” ve “Lapa” tarafından, denetimli derin beslemeli çok katmanlı algılayıcılar için ilk derin öğrenme algoritması yayınlandı. Her katmanda en iyi özellikler istatistiksel yöntemlerle seçilerek bir sonraki katmana taşınmıştır. Ağlarını uçtan uca eğitmek için ileri beslemeli sinir ağı kullanıldı. Önceki katmanlardan sonraki katmanlara kadar en küçük kareler yöntemi kullanıldı (95).



Şekil 17. İlk derin ağ mimarisi (Ivankhnenko'dan, 96)

İlk derin öğrenme mimarisi olan “Neocognitron”, Ivankhnenko'dan sonra 1979'da “Fukushima” tarafından önerildi. Kendi kendine öğrenen ağ, omurgalıların görsel sinir sisteminden esinlenen bir yapıda "denetimsiz öğrenme" ile geliştirildi. Fukushima ağları, modern ağlara benzer şekilde birkaç evrişim ve havuz katmanı içerir (97). Birden çok derin mimari düzeyindeki hataların geri yayılması, önemli bir öğrenme eksikliğine neden olmaktadır. Geri yayılım algoritmaları önceki yıllarda tanıtılmış olmasına rağmen, derin sinir ağları için ilk başarılı uygulama Yann LeCunn ve arkadaşları tarafından geliştirilmiştir (98). Ağ iyi çalışmasına rağmen eğitimi yaklaşık 3 gün sürdüğü için pratikte uygun olmadığı kanıtlanmıştır.


Bu çalışmayı takiben “Yann LeCunn”, LeNet ağını kullanarak el yazısıyla yazılan sayı sınıflandırması (MNIST) için evrişimli sinir ağını uyguladı (99). 1995 yılında, “Brendan Frey”, “Peter Dayan” ve “Geoffrey Hinton”, ağı eğitiminin iki gün sürdüğü bilinen altısı tamamen birbirine bağlı yüzlerce gizli katman içeren bir ağı eğitilebileceği bir uyanık uyku(wake-sleep) algoritması geliştirdiler (100). 1997'de “Hochreiter ve Schmidhuber” tarafından sunulan tekrarlayan sinir ağları için bazı önemli gelişmeler fark edildi (101). Bu dönemlerde YSA algoritmaları, avantajlarına rağmen hesaplama maliyeti nedeniyle kullanılamamıştır. 1990'lardan 2000'lere kadar, belirli problemlerle çalışan ve elle oluşturulan fonksiyonları kullanan destek vektör makineleri gibi daha basit modeller kullanılmıştır (102).

Bilgisayarların artan çalışma hızı ve grafik işlem birimlerinin (GPU'lar) hesaplamada kullanımıyla, büyük adımlar atıldı; hesaplama hızı 10 yılda neredeyse 1000 kat arttı. Bu yıllarda YSA, destek vektör makineleri ile rekabet etmeye başladı. İlk olarak

"Derin Öğrenme" terimi 2000'de "Igor Aizenberg" ve arkadaşları tarafından tanıtıldı (103). "Jeffrey Hinton" tarafından 2006'da yayınlanan bir makalede, ileri beslemeli çok katmanlı bir sinir ağının, yineleme başına bir katmanı nasıl verimli bir şekilde eğitebildiğini ve ardından denetimli bir geri yayılım algoritması kullanılarak derin öğrenme kavramının gelişmeye başladığını gösterdi (104).

2.8.3. Derin Öğrenme Tanım

Derin öğrenme, makine öğrenimi sınıflama yöntemlerinden biridir. Derin öğrenme, belirli bir veri kümesinden sonuçları tahmin eden çok katmanlı bir makine öğrenimi tekniğidir. Derin öğrenme yönteminde, özellik çıkarma ve dönüştürme gibi işlemler, birçok doğrusal olmayan işlem birimi katmanı kullanılarak gerçekleştirilir. Birbirini izleyen her katman, bir önceki katmanın çıktısını girdi olarak alır (105). Şekil 17'de derin sinir ağı yapısı verilmiştir.



Şekil 18. Derin sinir ağı yapısı (Kim'den, 106).

Derin öğrenme yaklaşımı birden çok soyutlama düzeyine sahip veri temsillerini öğrenmek için birleştirilmiş çoklu işlem katmanlarından oluşur (107). Derin öğrenme, birden fazla soyutlama ve veri temsili çalışmasına dayanan bir yapıya sahiptir. Üst düzey özellikler, alt düzey özelliklerden türetilen hiyerarşik bir görünüm oluşturur. Bu görünüm, çeşitli soyutlama düzeylerine karşılık gelen temsil düzeylerini öğrenmektedir (108). Düşük seviyeli özelliklerden yüksek seviyeli özellikleri türeterek veri sınıflandırma ve tanımayı hedefleyen derin öğrenme algoritmaları, geleneksel makine öğrenimi yöntemlerinin aksine problem çözmede ve büyük verilerin analizinde oldukça başarılı olduğu görülmüştür.

Derin öğrenme; nesne tanıma, konuşma tanıma, doğal dil işleme gibi alanlarda çok katmanlı yapay sinir ağlarını kullanan bir yapay zekâ tekniğidir. Derin öğrenme,

geleneksel makine öğrenimi algoritmalarının aksine, kodlanmış kurallardan öğrenmek yerine; görüntülerin, videoların, seslerin ve metinlerin veri sembollerinden öğrenebilirler (109). Çok yönlülükleri nedeniyle, ham görüntülerden veya metin verilerinden çıkarım yapabilir ve tahmin doğruluğu verilerin boyutuna bağlı olarak artabilir. Bununla birlikte, derin öğrenme, öğrenme işlemini örnekler üzerinden gerçekleştirir. Bir makine tarafından çözülecek bir problem için kurallar seti kullanmak yerine, makinenin problemi örnekleri değerlendirerek çözmesine imkân veren bir model sağlamak yeterlidir. Bir problemi çözerken bir hatayı düzeltmek için, makinenin basit bir komut listesi yayınlayarak eğitim sürecini tamamlaması gerekir. Model seçimi, bir problemin çözümünde etkilidir. Soruna göre belirlenecek model, çözümüne daha elverişli olacaktır. Derin öğrenme kavramı ilk olarak, çok katmanlı sinir ağlarının daha verimli bir şekilde eğitilebileceği önerildiği 2006 yılında Hinton tarafından tanıtıldı (95).

Başlıca derin öğrenme algoritmaları gösterilmiştir.


- Konvolüsyonel Sinir Ağları (Evrişimli Sinir Ağı-CNN)
- Tekrarlı Sinir Ağları (RNN)
- Kısıtlı Boltzmann Makineleri
- Derin İnanç Ağları
- Derin Oto-Kodlayıcılar

Konvolüsyonel sinir ağlarının (CNN), belirli bir veri setinden yüksek doğru sınıflandırılma oranı ve yüksek tahmin değeri elde edildiğinden dolayı bu tez çalışmasında konvolüsyonel sinir ağları (CNN) yöntemi kullanılmıştır (4, 5).

2.8.4. Konvolüsyonel Sinir Ağları (Evrişimli Sinir Ağı-CNN)

Bir Konvolüsyonel Sinir Ağı (CNN), Çok Katmanlı Algılayıcı-MLP sınıflandırıcısının bir türüdür. Görselin merkezindeki hücrelerin, tüm görüntüye odaklanarak, tüm görüntüyü kapsayacak şekilde alt bölgelere, basit sinir hücrelerine ve daha büyük reseptörlü karmaşık hücrelere ayrıldığına inanılır. CNN algoritması, hayvanların görsel merkezi esas alınarak oluşturuldu. Matematiksel evrişim süreci burada bir nöronun uyarı bölgesindeki uyaranlara tepkisi olarak düşünülebilir (110). Bir CNN, bir veya daha fazla evrişimli katman, bir alt örnekleme katmanı ve ardından standart birçok katmanlı sinir ağı gibi bir veya daha fazla tamamen bağlı katmandan oluşur (107).

Şekil 19'da gösterilen ilk CNN, 1988'de “Yann LeCun” tarafından önerilen ve 1998'e kadar geliştirilen LeNet adlı bir mimaridir (111). LeNet'te, alt katmanlar sıralı evrişim ve maksimum havuzlama katmanlarından oluşur. Sonraki üst katmanlar, tam bağlantılı geleneksel bir MLP sınıflandırıcı özelliği gösterir.



Şekil 19. LeNet ağının mimarisi (Yann LeCun'den, 111)

CNN algoritmaları, özellikle görüntü ve ses işleme alanında doğal dil işleme (NLP), biyotıp gibi birçok alanda kullanılmaktadır. En iyi sonuçlar özellikle görüntü işleme alanında elde edilmiştir. Ciresan, MNIST veri seti çalışmasında CNN kullanarak hata oranını %2'ye düşürmeyi başardı. Ciresan ve ark. tarafından yapılan başka bir çalışmada. MNIST ve NORB veri setlerinde, CNN ile eğitim süresinin kısaldığı görüldü ve o zamana kadar yöntemlerin en başarılısı olduğu belirtildi (112). 2014 yılında, ImageNet Yarışması'nda, nesne sınıflandırma ve tespitinde en iyi derecelere sahip ekipler, milyonlarca görüntü ve yüzlerce nesne sınıfı için CNN algoritmalarında değişiklikler yapmışlardır. 2015 yılında gerçekleştirilen çalışmada CNN, ters yüzler de dahil olmak üzere çeşitli açılardan yüzleri yakalayabildi. Bu ağ, farklı açı ve yönlerde yüzler içeren 200 bin görüntü ve yüzüz 20 milyon görüntüden oluşan bir veri tabanı üzerinde eğitildi (113).

CNN modellerinin görüntü işleme için kullanılabileceği gibi çeşitli NLP problemleri içinde kullanılabileceği literatür çalışmalarında gösterilmiştir. Bu çalışmalarda, anlamsal çözümleme, arama sorgularını alma, cümle modelleme, sınıflandırma, tahmin problemlerinde etkili olduğu gösterilmiştir (4, 5). CNN, ilaç araştırmalarında da tercih edilmiştir. Atomwise tarafından 2015 yılında oluşturulan “AtomNet”, ilaç geliştirme için oluşturulan ilk derin sinir ağıydı (114). Ebola ve skleroz gibi hastalıklarda yeni biyomolekülleri saptamak için üç boyutlu kimyasal reaksiyonları temsil etmek üzere eğitilmiş bir sistem kullanılmıştır (115). CNN, Go oynamak için de kullanıldı ve önceden eğitilmiş 12 katmanlı CNN modeli, oyunların %97'sinde geleneksel GNU Go algoritmasını

geçti (116). Google DeepMind tarafından oluşturulan CNN tabanlı AlphaGo programı, profesyonel bir oyuncuyu (insan) ilk yenen programdı (117).

2.8.5. Tekrarlı Sinir Ağları (RNN)

RNN'ler, bir sonraki adımı tahmin etmek için yaygın olarak kullanılan bir tür derin öğrenme yapılarıdır. Metin ve ses verileri, sınıflandırma problemleri, regresyon problemleri gibi alanlarda kullanılmaktadır. Diğer derin öğrenme yapılarından en büyük farkı, bir sonraki adımı takip edebilmek için girdiler arasında ilişki kurarlar ve eğitim aşamasında tüm ilişkilerini hatırlar. Diğer bir fark ise, diğer sinir ağlarında her girdi birbirinden bağımsız iken, RNN'de girdiler birbirine bağlıdır. Bir önceki nöron ile bağlantılıdır böylece bir sonraki nörona bilgi kaybı olmadan ilerlenir. Ancak uzun girdileri işlemekte güçlük çeker (118).

2.8.6. Kısıtlı Boltzmann Makineleri (RBM)

Hinton'un kısıtlı Boltzmann makinesi genellikle sınıflandırma, regresyon ve özellik seçimi gibi alanlarda yaygın olarak kullanılmaktadır. RBM, bir veri kümesi için olasılık dağılımlarını öğrenebilen stokastik ve üretken sinir ağlarıdır. RBM'ler, derin inanç ağlarının yapı taşlarını oluşturan iki katmanlı sinir ağlarıdır. RBM'nin ilk katmanına görünür birimler, ikinci katmana ise gizli birimler denir. Her daire (düğüm) bir nöronu işaret eder. Nöronlar, gizli bloklar ve görünür bloklar arasında bağlanır, ancak aynı katmandaki iki nöron arasında, yani görünür bir birim ile görünür bir birim, bir gizli birim ve bir gizli birim arasında bağlantı yoktur. Dolayısıyla bu, katmanlar arasında bağlantı bulunmadığı için sınırlı bir Boltzmann makinesi olduğu anlamına gelir. Her nöron bilgiyi değerlendirir ve bu bilgi bir sonraki nörona iletip iletmeme konusunda rastgele kararlar verir. Üretken model, her yeni katman eklendikçe gelişir (119).

2.8.7. Derin İnanç Ağları (DBN)

Makine öğrenmesinde derin inanç ağı (DBN), katmanlar arasında bağlantıya sahip, çok sayıda gizli düğüm katmanından oluşan ancak düğümler arasında bağlantı olmayan bir derin sinir ağı sınıfıdır. DBN, günümüzde kümeleme, sınıflandırma, boyut indirgeme, anormallik tespiti, doğal dil işleme alanlarında sıklıkla tercih edilmektedir. DBN, denetimsiz bir dizi örnek üzerinde eğitim gördüğünde girdilerini olasılıksal bir şekilde yeniden yapılandırmayı öğrenebilir. Katmanlardan daha sonra özellik seçimi yapılabilir. Bu eğitim aşamasından sonra DBN, sınıflandırma yapmak için daha fazla veri ile

eğitilebilir. DBN'ler, Kısıtlı Boltzmann Makineleri (RBM'ler) veya otomatik kodlayıcılar gibi basit, denetimsiz ağların bir birleşimi olarak düşünülebilir; burada her bir alt ağ, bir sonrakinin görünür katmanı olan gizli bir katman olarak işlev görür (120).

2.8.8. Derin Oto-Kodlayıcı (AE)

Otomatik kodlayıcılar (AE), genellikle denetimsiz öğrenme için tercih edilen özel bir yapay sinir ağıdır. AE, genellikle özellikleri sınıflandırma ve görüntü tanımlama alanında kullanılmaktadır. AE, girdi katmanındaki veriler önce kodlayıcı katmanlar ile sıkıştırılır. Sıkıştırılan öznitelikler kod çözücü katmanlar ile çıktı katmanına aktarılır. Böylece, AE girdi katmanındaki verileri çıktı katmanına kopyalayan bir sinir ağıdır. Başlangıçta yapay sinir ağına girdi olarak verilen verileri çıktı katmanında yeniden oluşturur. AE, girdi verilerinin sıkıştırılmış bir temsilinden en iyi özellikleri öğrenmeyi amaçlayan ileri beslemeli bir sinir ağıdır (121).

3. GEREÇ ve YÖNTEM

Bu tez çalışmasında lojistik regresyon analizinde geriye doğru adımsal eleme yöntemi kullanılarak önemli parametreler belirlenmiştir. Bu parametreler kullanılarak derin öğrenme yaklaşımının bir algoritması olan Konvolüsyonel sinir ağı (CNN) tabanlı bir karar destek modeli geliştirilmiştir. Bu yöntemler sırayla incelenecektir.

3.1. Lojistik Regresyon Geriye Doğru Eleme Yöntemi (Backward Stepwise)

Lojistik regresyon modelinde değişkenleri seçmek için birçok farklı yöntem vardır. Bir model için değişken seçme yöntemleri arasında standart (enter) ve adımsal (stepwise) değişkenleri seçmeye yönelik iki ana yöntem yaygın olarak kullanılmaktadır. Adımsal yöntemlerde kendi içinde “ileri doğru seçim” (forward selection) ve “geriye doğru eleme” (backward selection) olarak iki grupta ele alınır (56). F-testi, hata teriminin normal dağılımı nedeniyle yeni bir değişkenin modele katkısının önemini belirlemek için doğrusal regresyon analizinde kullanılsa da lojistik regresyon modelinde hata terimleri bir binom dağılımı göstereceğinden, bu G istatistiği ile belirlenir.

İleri yönlü seçim yönteminde, yeni değişken uyumu iyileştirene kadar değişkenler modele katılır. Her aşamada uyumu en çok iyileştiren değişken seçilir. Geriye doğru eleme yönteminde değişkenlerin tümünü modele dahil ederek başlar ve modele en az etkisi olan değişkenler sırayla modelden çıkarılır. Her adım, model üzerinde en az etkiye sahip değişkeni kaldırarak en uygun modeli bulmaya çalışır.

Olabilirlik oranı testi, modeldeki açıklayıcı değişkenler için tüm p katsayılarının önemini test etmek için de kullanılabilir. Bir modelin anlamlı olup olmadığını belirlerken, değişken (ler) içermeyen modelin log olasılığı, değişken (ler) ile modelin log olasılığı ile karşılaştırılmalıdır. Bu durum için G istatistiği “Eşitlik 24” ifadesi ile hesaplanır:

$$G = -2\ln [\text{değişken (ler)siz log olasılığı/değişken (ler)li log olasılığı}] \quad (\text{Eşitlik 24})$$

Modelin önemini test etmeye yönelik hipotez testleri aşağıdaki gibidir:

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


$$H_1 = \text{En az biri 0'dan farklı}$$

G istatistiği, $(\gamma_2 - \gamma_1)$ serbestlik dereceli ki-kare dağılımına dönüşür. Serbestlik derecesini hesaplamak için kullanılacak γ_2 değeri, tüm modeldeki değişken sayısı 1 artırılarak,

indirgenmiş modelde ise değişken sayısı 1 arttırılarak γ_1 değeri hesaplanacaktır. Yukarıdaki H_0 hipotez reddedilirse modelin anlamlı olduğu, H_0 hipotez kabul edilirse indirgenmiş modelin tüm model kadar iyi olabileceği sonucuna varılır. Değişken seçiminde adımsal bir yöntem kullanmak istendiğinde, "geriye doğru eleme", "ileri yönlü seçime" göre tercih edilmelidir. Çünkü ileri yönlü seçimin baskılayıcı etkisine bağlı olarak Tip II hata görülebilir (122).

3.2. Konvolüsyonel Sinir Ağları (CNN)

Konvolüsyonel sinir ağları (CNN), çok katmanlı algılayıcıların (MLP) özel bir türüdür. Konvolüsyonel sinir ağları, görüntü tanıma, sınıflandırma ve tahmin problemlerinde yaygın olarak kullanılmaktadır. Konvolüsyonel sinir ağları görüntü verilerini kullanmak için genellikle tercih edilse de diğer veri türlerine de uygulanabilir (123). Tablosal özellikler uzamsal olarak ilişkili olmadığından, tablosal bir veri kümesi doğrudan bir evrişim katmanına girilemez. CNN, bitişik sütunların uzamsal ilişkisine dayanan bir derin öğrenme tekniğidir. Bu nedenle, tablo verileri dönüştürülerek özellik boyutu yeniden boyutlandırılır. Bu dönüşümün amacı, oluşturulan görüntüyü (özellik boyutu) özellik sıralaması yoluyla anlamlı hale getirmektir. İleri sinir ağlarından biri olan CNN, her katmanın farklı özellikleri tanımak üzere eğitildiği çok katmanlı bir yapıya sahiptir (124). Giriş verilerindeki bilgiler sırasıyla konvolüsyon katmanından, havuzlama katmanı ve tamamen bağlı katmandan çıktı katmanına geçer. Çıktı katmanının çıktısı, bir veya birden fazla sınıfların olasılığı olarak temsil edilir (3). Günümüzde birçok alanda başarılı sonuçlar veren CNN ağının temel mimarisi Şekil 20’de gösterilmektedir.



Şekil 20. CNN ağının temel mimarisi (Hidaka’dan, 125)

3.2.1. Giriş Katmanı (Input Layer)

Dış dünyadan gelen verilerin konvolüsyonel sinir ağına girdiği katmandır. Giriş katmanında, dış dünyadan gelen girdiler kadar çok sayıda nöron olmasına rağmen, giriş verilerine genellikle işlem yapılmadan alt katmanlara aktarılır (126).

3.2.2. Konvolüsyon Katmanı (Convolutional Layer)

CNN mimarisinin ilk katmanı konvolüsyon katmanıdır. Belki de en önemli CNN katmanı diyebileceğimiz bu katmanda, belirli bir boyutta bir filtre görüntü matrisi üzerinde dolaştırılarak bir çıkış verisi ve ardından öznitelik haritası oluşturulur (127). Bu işlem, görüntü matrisini en iyi tanımlayan özelliklerin çıkarılmasını sağlar. Konvolüsyon işlemi sonucunda yeni bir görüntü matrisi elde edilir. Buna göre görüntünün hangi ilgili alanının önemli olduğu belirlenir. Kullanılan filtreler farklı boyutlarda olabilir, örneğin 2,3,4 gibi. Sürecin sonunda, özellik haritasının çıkarılması verilerin daha iyi analiz edilmesine yardımcı olur (126).

3.2.2.1. Aktivasyon Fonksiyonu

Aktivasyon fonksiyonları; Nöronların çıktısını bir katmandan başka bir katmana geçirirken kullanılır. YSA, çeşitli ağırlık ve bias değerleri çarparak ve ekleyerek hesaplamalar yapar. Ortaya çıkan büyük sayıları azaltarak iş daha kolay hale getirilebilir. Bu işleme araçlarından biri, aktivasyon fonksiyonu kullanılarak büyük sayıları seçilen aktivasyon fonksiyonu türüne bağlı olarak -1 ile 1 arasında bir değer ile temsil etmektir. Böylelikle büyük değerlerden kurtulur ve onu izleyen katmanın bağımsızlığını artırır. Ek olarak, aktivasyon fonksiyonları, yapay sinir ağlarının doğrusal olmayan bir yapı kazanmasına izin verir. ReLu aktivasyon fonksiyonu genellikle derin ağlarda kullanılır (3).

Konvolüsyon işlemi tamamlanmasından sonra, sonuç matrisi sonraki katman için girdi olarak kullanılmaya devam eder. Sonuç matrisi negatif değerler içeriyorsa, bu negatif değerler ReLU aktivasyon fonksiyonu kullanılarak sıfırlanır. ReLU aktivasyon fonksiyonuna sağlanan değer pozitif bir değer ise, giriş değeri bir çıkış değeri olarak yansıtılırken, giriş değeri negatif bir değer iken, giriş değeri bir sıfır çıkış değeridir. ReLU özelliğinin en önemli faydalarından biri, eğitim sırasında olasılıklı gradyan azaltma (SGD) gibi öğrenme algoritmalarının yakınsamasını önemli ölçüde hızlandırmasıdır (125).

Bu tez çalışmasında ağı eğitilmesinde ara katmanların aktivasyon fonksiyonu olarak ReLU fonksiyonu kullanılmış ve son katmanda her bir çıktı sınıfının olasılığı tahmin etmek için Softmax fonksiyonu kullanılmıştır.

3.2.3. Havuzlama katmanı (Max-Pooling Layer)

Havuzlama katmanı hesaplama yapılan katmandır. Burada işlem yapıldığında parametre değerleri yarıya indirilir. Böylelikle bir sonraki hesaplamanın maliyeti azaltılır ve satır-sütundaki kaymalar sonucu değişen özellik haritası ile ağı ezberlenmesi engellenir. Bu katmanın amacı, konvolüsyon katmanını yeniden boyutlandırmak ve model performansını iyileştirmek için özellik çıkarmaktır (126).

Adından da anlaşılacağı gibi, maksimum havuzlama matristeki en yüksek değeri alır. Bir kayan filtre uygulandığında, matristeki her adımda maksimum değer alınır ve bununla alt örnekleme yapılır. Konvolüsyon katmanından farklı olarak, havuzlama katmanı ağı derinliğini etkilemez (127).

3.2.4. Tam Bağlı Katman (Fully Connected Layer)

CNN mimarisindeki son katman, tam bağlı katmandır (fully connected layer). Tamamen bağlı katmandaki nöronlar, tıpkı yapay sinir ağlarında olduğu gibi, önceki katmandaki tüm aktivasyonlara tamamen bağlıdır. Bu katmanın görevi, girdi verisinden çıkarılan özellikleri sınıflandırmaktır. Tam bağlantı katmanına girdi olarak gelen veri matrisi, düzleştirme (flatten) adımı uygulandıktan sonra gelir. Havuzlama ve filtreleme katmanlarında çeşitli işlemlerden geçen veri matrisi, düzleştirme işleminden sonra tam bağlantı katmanına dahil edilir (118). Tamamen bağlı katmanlar ve konvolüsyon katmanları arasındaki fark, konvolüsyon katmanındaki nöronların yalnızca yerel giriş alanına bağlanması ve bu katmandaki çoğu nöronun parametreleri paylaşmasıdır (127). Bununla birlikte, her iki katmandaki nöronlar nokta çarpımı hesapladığından, fonksiyonel formları aynıdır. Bu katmandaki tüm nöronlar birbirine bağlı olduğu için buna tamamen bağlı katman denir. Çoğu CNN mimarisi, tam bir bağlantı katmanı ile sona erer ve ardından aktivasyon fonksiyonu ile sınıflandırılır (124).

3.2.5. Çıkış Katmanı (Output Layer)

Tam bağlantılı katmandan sonra çıkış katmanı veya sınıflandırma katmanı kullanılır. Sınıflandırılacak nesnelerin sayısı ve sınıflandırma katmanının çıktı değeri

eşleşmelidir. Bu katmanda çeşitli sınıflandırıcılar kullanılır. Softmax sınıflandırıcı, başarısı nedeniyle en çok tercih edilmektedir (126).

3.2.5.1. Softmax

Softmax, bir istatistiksel olayın olasılık dağılımını "n" farklı olaya göre hesaplar. Tipik olarak bu işlev, tüm olası hedef sınıflar genelinde her bir hedef sınıfın olasılıklarını hesaplar. Verilen girdiler için hedef sınıfın çıktısı hesaplanan olasılık değerleri yardımıyla belirlenir. “Eşitlik 24” giriş değerinin üstel (e sayısının kuvveti) değerini ve tüm girdilerdeki üstel değerlerin toplamını hesaplar (125). Bu nedenle, bu iki değer oranı softmax fonksiyonunun çıktısıdır. Burada p , her girdinin i indisli bir elemanla temsil edildiği bir vektördür (bu çalışmada ikili sınıflandırmadan dolayı 2 çıktı birimi vardır, bu yüzden 2 elemanı vardır). Buna ek olarak, i çıktı biriminin indeksidir, yani $i = 1, 2 \dots k$.

$$f(p)_i = \frac{e^{p_i}}{\sum_{k=1}^k e^{p_k}} \quad (\text{Eşitlik 24})$$

Bu tez çalışmasında sınıflandırma katmanının ikili sonuç (bıraktı- bırakmadı) vermesi amaçlanmaktadır. Hedef sınıflar için Softmax sınıflandırıcının olasılık değeri kullanılarak sigara bırakma düzeyleri sınıflandırılması yapılmıştır.

3.3. Google Colab

Tez çalışması kapsamında Google Colaboratory, kısaca Colab, derin sinir ağı modellerini eğitmek için kullanılan bir geliştirme ortamıdır. Makine öğrenimi algoritmalarının geliştirilmesine yardımcı olmak için oluşturulmuş bir projedir.

Google tarafından geliştirilen Colab platformu, kullanıcılara ücretsiz bulut hizmeti ve GPU desteği sunmaktadır. Bu şekilde, kullanıcılar kendilerine sağlanan belirli kapasiteye sahip Python uygulamaları geliştirebilirler. Geliştirilen uygulamalar Google Drive'da saklanır. Ayrıca derin öğrenme uygulamaları geliştirilmesi için Keras, OpenCv, XGBoots, PyTorch, Sklearn ve TensorFlow gibi kütüphanelerin kullanılmasına olanak sağlar.

Platformun kullanıcılara sunduğu donanım özellikleri: Tesla K 80 grafik işlem birimi (GPU), 2,3 GHz Intel Xeon merkezi işlem birimi (CPU), 2 çekirdek, 12 GB RAM ve 311 GB disk kapasitesi. Ancak bu sanal makinede her 12 saatte bir Disk, RAM, CPU ve önbellekteki veriler silinir. Bu nedenle geliştiricilerin 12 saatte bir işlemlerini tekrar

etmesi gerekmektedir. Bu tez çalışmasında CNN tabanlı karar destek sisteminin geliştirilmesi Google Colab platformu kullanılarak yapılmıştır.

3.4. Verilerin Hazırlanması

Bu çalışmada kullanılan veri seti, 2015-2020 yılları arasında Karadeniz Teknik Üniversitesi Farabi Hastanesi Göğüs Hastalıkları Anabilim Dalı Sigara Bırakma Polikliniğine başvuran 383 hastadan oluşmaktadır. Sigara Bırakma Polikliniğine ilk başvurularında alınan bilgilere göre doldurulan tıbbi kayıtları incelendikten sonra telefonla ulaşılabilen ve çalışma hakkında bilgi verildikten sonra çalışmaya katılmayı kabul eden toplam 383 hasta dahil edildi. Çalışma, Karadeniz Teknik Üniversitesi Farabi Hastanesi ve belirtilen tarihlerde dahil edilme kriterlerini karşılayan 383 katılımcının katılımıyla tamamlandı.

Çalışmanın şartları aşağıda verilmiştir.

- Karadeniz Teknik Üniversitesi Farabi Hastanesi Göğüs Hastalıkları Anabilim Dalı Sigara Bırakma Polikliniğine başvuru yapmış olmak
- 18 yaş ve üzeri olmak
- Telefonla ulaşılabilen ve çalışmaya katılmaya gönüllü olmak

Veri toplama, dosyalar taranarak ve telefonla anket doldurularak gerçekleştirildi. Veri toplama aracı olarak; Hastaların sosyodemografik ve sigara özelliklerini içeren sigara bırakma polikliniği veri formu ve Fagerstörn nikotin bağımlılığı testi kullanıldı.

Veri toplama aşamasından sonra veriler IBM SPSS23 ve Rstudio 3.6.1 programları kullanılarak düzenlenmiş ve analiz edilmiştir. Veri setindeki parametrelerin seçimi ve laboratuvar test sonuçları, bir uzman hekim tavsiyesi altında incelenerek elde edildi. Lojistik regresyon yöntemiyle özniteliklerin analizi yapılmış ve önemli öznitelikler belirlenmiştir. Bu öznitelikler karar destek sistemi için bir veri seti olarak kullanılmıştır.


Derin öğrenme yaklaşımı ile sigara bırakma tedavisinin belirlenmesi için karar destek sistemi Google Colaboratory platformu ile geliştirildi. Google Colaboratory, derin öğrenme uygulamaları geliştirilmesi için Keras, OpenCv, XGBoots, PyTorch, Sklearn ve TensorFlow gibi kütüphanelerin kullanılmasına olanak sağlar. Başlangıçta, 383 hastanın verisi kullanılarak sentetik veri artırma yöntemi ile 1000 hasta verisi üretildi. Veri seti %80 eğitim verisi ve %20 test verisi olmak üzere rastgele bölünmüştür. Kullanılan veri setinin dağılımı Tablo 8’de gösterilmiştir.

Tablo 8. Veri seti dağılımı

Veri Seti	Veri Yüzdesi	Veri Sayısı
Eğitim	%80	800
Test	%20	200

3.5. Sınıflandırmak için Tasarlanan CNN Yapısı

Çalışmada kullanılan CNN yapısında, Python programlama dilinde Keras ve TensorFlow kütüphaneleri kullanıldı. Sistemi eğitmek için farklı modeller oluşturularak, öğrenme katsayısı, aktivasyon fonksiyonu, optimizasyon yöntemleri, eğitim tur sayısı, batch boyutu gibi farklı model performans ölçme yöntemleriyle modellerin performansları ölçülüp, karşılaştırılmıştır. Geleneksel makine öğrenmesinin temel algoritmalarını daha modern ve yenilikçi öğrenme ilkesi kullanan CNN ile karşılaştırılarak sonuçlardaki farklılıklar incelenmiştir. Bu tez çalışmasında denemeler ve araştırmalar sonucunda incelenen veri setine uygun bir CNN modeli oluşturulmaya çalışılmıştır. Veri seti için kurulan CNN model Şekil 21’de gösterilmiştir.



Şekil 21. Veri seti için kurulan CNN modeli

CNN yapısında hiperparametreleri belirlemek için spesifik bir yöntem olmadığından, hiperparametreler deneme yanılma yöntemi ile elde edilen sonuçlara göre seçilmiştir. Bu hiperparametrelerden biri çekirdek boyutudur. Çekirdek boyutu, farklı boyutlardaki özellikleri algılayacak ve bu nedenle farklı boyutlu özellik haritalarının oluşmasına neden olacaktır. Çekirdek her hücre için giriş vektörü boyunca hareket ettirilir. Giriş vektörü konvolüsyon katmanında 0 normalizasyonu ile yeniden boyutlandırılmıştır. Konvolüsyon katmanı, her bir elemanı çekirdek ile çarparak ve son çıktı değerini elde etmek için çarpım sonucu toplanarak gerçekleştirilir. Bu çarpma ve toplamayı giriş vektörünün sonuna kadar birbiri ardına tekrarlanır ve çıkış vektörü elde edilir. Çekirdek boyutunun büyütülmesi doğruluk değerinde bir artış gösterse bile aşırı öğrenme problemine neden olmaktadır. Bu çalışmada, çekirdek boyutu 1x2 olarak seçilmiştir. Oluşturulan model, iki konvolüsyon katmanı ve iki havuzlama katmanından oluşmaktadır.

CNN'i hesaplama yükü açısından bu kadar işlevsel kılan en önemli katman havuzlama katmanıdır. Havuzlama katmanına, her bir özellik haritasını boyutsallığını küçülten ama önemli bilgileri tutan alt örnekleme de denir. Maksimum havuzlama, özellik haritasındaki en büyük değeri alır.

Son olarak, çıkarılan özellik haritaları, matris düzleştirme işleminden sonra vektör sınıflandırma işlemi için tamamen bağlı katmana aktarılır. Öğrenme modeli, tamamen bağlantılı bir katmandaki özelliklerin bir kombinasyonundan oluşur. Eğitim sırasında oluşan hataları dikkate alan Adam'ın optimizasyon algoritması, sadece kare gradyanın üstel ağırlıklı ortalamasını kullanmakla kalmaz, aynı zamanda momentumdaki değişiklikleri önbellekte depolar ve uygun adımlarla istenilen hedefe doğru hareket etmesini sağlar. Model kayıp fonksiyonu categorical crossentropy tercih edilmiştir çünkü ikili sınıflandırma için uygundur. Sınıflandırma işleminin gerçekleştiği tam bağlantılı katmanın son aktivasyon fonksiyonu olan Softmax ile nihai sonucun, yani sigara içme bağımlılığını bıraktı veya bırakmadı olduğu sonucuna varılır. CNN'in çalışma tarzı, belirtilen sorunlar açısından tüm ağıdaki parametreleri kademeli olarak azaltmanın ve basitleştirmenin bir yolu olarak açıklanabilir. Sınıflandırmak için tasarlanan CNN modelinin detayları Tablo 9'da gösterilmiştir.

Tablo 9. Sınıflandırmak için tasarlanan CNN modelinin detayları

Katman (Türü)	Çıktı Şekli	Parametre
INPUT (12x1)	Giriş Görüntüsü(4x4x1)	0 normalizasyonu ile (4x4x1) giriş görüntüsü
Conv2d (Conv2D)	(None, 3, 3, 64)	320
Max_Pooling2d (Maxpooling2d)	(None, 3, 3, 64)	0
Conv2d_1 (Conv2D)	(None, 2, 2, 32)	8224
Max_Pooling2d_1 (Maxpooling2d)	(None, 2, 2, 32)	0
Flatten (Flatten)	(None, 128)	0
Dense (Dense)	(None, 100)	12900
Dropout (Dropout)	(None, 100)	0
Dense_1 (Dense)	(None, 100)	10100
Dropout_1 (Dropout)	(None, 100)	0
Dense_2 (Dense)	(None, 2)	202
Toplam parametre= 31746		
Eğitilen parametre= 31746		
Eğitilemeyen parametre=0		

Python programındaki modelin ayrıntılı bir açıklaması tablo 10'da verilmiştir. Tablo 10'da gösterildiği gibi, konvolüsyon katmanında oluşturulan özellik haritalarının boyutu, maksimum havuzlama katmanı tarafından küçültülmekte ve tam bağlantılı katmana aktarılmaktadır. Boyuttaki bu azalma, öğrenilebilir parametrelerin sayısını etkilemekte ve azaltmaktadır. Verilerimiz tablo verisi olduğundan tek boyutludur. Bu yüzden tek boyutlu olan özellik haritamız yeniden boyutlandırma işlemi ile iki boyutlu hale getirilmiştir. Bir kare matris işlevi sağlamak için 0 normalleştirme uygulandı. Yani özellik haritamız 12x1 olmasına rağmen 0 normalizasyonu kullanılarak 16x1 şekline dönüştürüldü. İki boyutlu dönüşüm uygulanarak özellik haritamız 4x4x1 olarak yeniden boyutlandırılmıştır. Modelin giriş katmanında 4x4x1 piksel boyutlu görüntülere konvolüsyon katmanında 1x2 boyutlu 64 filtre kullanılmıştır ve aktivasyon fonksiyonu relu olarak tercih edilmiştir. İkinci katmanda görüntüye 1x1 piksel boyutlu havuzlama işlemi uygulandı. Üçüncü katmanda 2x2 boyutlu 32 filtre uygulandı ve aktivasyon fonksiyonu relu olarak tercih edilmiştir. Dördüncü katmanda görüntüye 1x1 piksel boyutlu havuzlama

işlemi uygulandı. Beşinci katmanda düzleştirme (flatten) işlemi uygulanarak veriler tek boyutlu bir diziye dönüştürülmüştür.

Tam bağlı katmanın ilk katmanında özellik boyutu giriş arttırıldı 100 nöron ve aktivasyon fonksiyonu relu olarak tercih edildi. Tam bağlı katmanın ikinci katmanında aşırı öğrenmeyi önlemek için dropout işlemi gerçekleştirilmiş ve eşik değeri 0.5 olarak ayarlanmıştır. Tam bağlı katmanın üçüncü katmanında 100 nöron ve aktivasyon fonksiyonu relu olarak tercih edildi. Tam bağlı katmanın dördüncü katmanında aşırı öğrenmeyi önlemek için dropout işlemi gerçekleştirilmiş ve eşik değeri 0.5 olarak ayarlanmıştır. Son katmanında ikili sınıflandırma nedeniyle iki nöron ve her bir sınıfın olasılık değeri istendiği için softmax fonksiyonu kullanılmıştır. Model kayıp fonksiyonu categorical crossentropy tercih edilmiştir. Modelde optimizasyon algoritması olarak adam tercih edilmiştir; öğrenme katsayısı 0.001 olarak belirlenmiştir. Öğrenme katsayısı, ağırlıkların ne sıklıkla güncellendiğini etkileyen bir parametredir. Amacı her adımda ağırlıkları güncelleyerek modele en uygun ağırlıkları bulmaktır. Bu süreci tekrar eden eğitimin her adımına epoch denir. Epoch sayısı için belirli bir değer yoktur, ancak her model için optimal bir değer vardır. Bu model için epoch sayısı 250 olarak ayarlanmıştır.

3.6. Veri Analizi

Bir bilimsel araştırmaya başlamadan önce, çalışmanın planlama aşamasında klinik ve istatistiksel olarak anlamlı sonuçlar elde etmek için akla gelen ilk soru “kaç kişi ile çalışmam gerekir?” sorusu olur ve çalışmada planlanan kişi sayısı araştırmanın örneklemini oluşturur. Makine öğrenimi modellerinin örneklem büyüklüğünü belirlemeye yönelik en popüler sistematik yaklaşımın, bir öğrenme eğrisi uydurma “post hoc yöntemi” olduğu görülmektedir. Temel olarak, verilerin tüm büyük alt kümeleri alınır ve hata değeri hesaplanır. Ardından, alt örnekteki gözlem sayısının bir fonksiyonu olarak bir güç yasası eğrisi çizilir. Ortaya çıkan eğri, istenen hata oranı için gerekli örnek boyutu hakkında bir sonuca varılmasını sağlar (130). Derin öğrenme yaklaşımında sistem üzerinde ne kadar gerçek veri eğitilirse, modelin hata oranı o derece azalacaktır (3).

İlk olarak veri setindeki değişkenlere kayıp değer analizi uygulanmıştır. Rastgele değerler, rastgele orman (RF) atama yöntemi kullanılarak eksik değerlere atanmıştır.

Veri analizi aşamasında IBM SPSS23 ve Rstudio 3.6.1 programı kullanılmıştır. Değerlendirme sonuçlarına ilişkin tanımlayıcı istatistikler; “Kategorik değişkenler” için sayıları ve yüzdeleri, “Sayısal değişkenler” için ortalama ve standart sapma olarak

belirtilmiştir. Kategorik değişkenler arasındaki ilişkiyi ölçmek için ki-kare istatistiği kullanıldı. Bağımsız değişkenlerin, bağımlı değişken üzerindeki etkisini ölçmek için lojistik regresyon analizi kullanılmıştır. İki bağımlı grubun karşılaştırılması; normal dağılım koşulu sağlandıysa, "İki Eş Arasındaki Farkın Önemlilik Testi" (paired t testi), değilse "Wilcoxon" testi değerlendirildi. İki bağımsız grup arasındaki sayısal değişkenler karşılaştırıldığında, normal dağılım koşulu sağlandığında "bağımsız gruplar T testi" (indepent sample T testi) sağlanmadığında "Mann-Whitney U" testi kullanıldı. İstatistiksel anlamlılık düzeyi $p<0.05$ olarak kabul edildi.



4. BULGULAR

4.1. Veri setinin Analizi

KTÜ Farabi Hastanesi Göğüs Hastalıkları Anabilim Dalı Sigara Bırakma Polikliniğine 2015-2020 yılları arasında başvurmuş 383 hastanın 133'ü (%34.7) kadın, 250'si (%65.3) erkekti. Hastaların yaş ortalamaları 39.7 ± 13 yıl (18-72 yaş) idi. Geriye yönelik verilerin kullanıldığı bu retrospektif çalışmada araştırmanın bağımsız değişkenleri sosyodemografik özelliklere ilişkin değişken ve ölçütler (Yaş, Cinsiyet, Medeni durum, Eğitim düzeyi, Gelir durumu, Çocuk sayısı), sigara kullanımına ilişkin değişken ve ölçütler (Sigara başlama yaşı, Günlük içilen sigara miktarı, Sigara tüketimi(paket yıl), Sigaraya başlama nedeni, Sigara miktarındaki değişiklikler, Sigarayı bırakmayı isteme nedeni) ve diğer değişkenler ve ölçütlerden (Kişisel-sosyal öykü, Aile öyküsü, Sistem sorgulama, Laboratuvar ölçümleri (Hemogram, lipid paneli, karaciğer fonksiyon testleri), Uygulanan tedavi değişkenlerinden oluşan bir veri seti kullanılmıştır. Araştırmanın bağımlı değişkeni sigara bırakma durumudur.

Tablo 10. Hastaların cinsiyete göre dağılımı

Cinsiyet	Sayısı	Oran %	Sigara bırakma Oranı%
Kadın	133	34.7	37.6
Erkek	250	65.3	41.2

Hastaların cinsiyete göre dağılımı Tablo 10'da tanımlanmıştır. Cinsiyetine göre 383 hastadan, 103'ü (%41.2) erkek, 50'si (%37.6) kadın olan hastalar sigara bırakma eylemini sonlandırmıştır. Sigara bırakma oranı ile cinsiyet faktörü arasında istatistiksel olarak önemli bir farklılık yoktur.

Tablo 11. Hastaların yaş dağılımı

Yaş(yıl)	Sayısı	Oran %	Sigara bırakma Oranı%
0-19 arası	9	2.3	44.4
20-29 arası	100	26.1	38
30-39 arası	85	22.2	37.6
40-49 arası	89	23.2	45
50-59 arası	73	19.1	35.6
60 ve üstü	27	7	48

Hastaların yaşa göre dağılımı Tablo 11’de tanımlanmıştır. Hastaların yaş değişkeni ile sigara bırakma oranı arasında önemli bir ilişki bulunamadı.

Tablo 12. Hastaların sigara kullanımına ilk başladıkları yaş değişkeni dağılımı

İlk Başlama Yaşı(yıl)	Sayısı	Oran %	Sigara bırakma Oranı%
0-19 arası	314	82	39.8
20-29 arası	66	17.2	39.3
30-39 arası	3	0.8	66.6

Hastaların ilk başlama yaşına göre dağılımı Tablo 12’de tanımlanmıştır. Hastaların sigara kullanımına ilk başladıkları yaş 6 ile 37 arasında değişiklik göstermektedir. Hastaların ilk başladıkları yaş ortalamaları 16 ± 4.4 yıldır. Hastaların ilk başlama yaş değişkeni ile sigara bırakma oranı arasında önemli bir ilişki bulunamadı.

Tablo 13. Hastaların düzenli olarak sigara kullanımına başladıkları yaş

Düzenli İçmeye Başlama Yaşı	Sayısı	Oran %	Sigara bırakma Oranı%
0-19 arası	233	60.8	37.3
20-29 arası	138	36	41.3
30-39 arası	9	2.3	88.8
40-49 arası	3	0.8	33.3

Hastaların düzenli olarak başlama yaşına göre dağılımı Tablo 13’te tanımlanmıştır. Sigaraya düzenli olarak başlanılan yaş ile sigara bırakma oranı arasında istatistiksel olarak önemli bir farklılık vardır ($\chi^2=9.80$; $p=0.020$). Bu farklılık hastaların düzenli olarak içmeye başladıkları 30-39 yaş grupları arasındaki bırakma oranından kaynaklanmaktadır.

Tablo 14. Hastaların medeni durumuna göre dağılımı

Medeni Durumu	Sayısı	Oran %	Sigara bırakma Oranı%
Bekar	108	28.2	38.8
Evli	256	66.8	40.6
Boşanmış-Dul	19	5	36.8

Tablo 14’te sunulduğu gibi hastaların medeni durumu evli olanların sigarayı bırakma oranı yüksek olduğu görülmektedir. Ancak hastaların medeni durumu ile sigara bırakma oranları arasında önemli bir farklılık bulunamamıştır.

Tablo 15. Hastaların eğitim durumuna göre dağılışı

Eğitim Durumu	Sayısı	Oran %	Sigara bırakma Oranı%
İlkokul	82	21.4	32.9
Ortaokul	43	11.2	41.8
Lise	112	29.2	41.9
Üniversite	146	38.1	41.7

Hastaların, Tablo 15’te verilen eğitim durumları göz önüne alındığında okur yazarlık oranı arttıkça sigara bırakma oranı arttığı görülmüştür. Ancak hastaların eğitim durumu ile sigara bırakma oranları arasında istatistiksel olarak anlamlı bir farklılık bulunamamıştır.

Tablo 16. Hastaların gelir düzeyine göre dağılışı

Gelir Düzeyi	Sayısı	Oran %	Sigara bırakma Oranı%
0-2500	262	68.4	37.4
2501-5000	96	25.1	43.7
5001-7500	16	4.2	50
7501-10000	8	2.1	62.5

Hastaların gelir dağılımı Tablo 16’da tanımlanmıştır. Gelir arttıkça sigara bırakma oranının artmış olduğu görülmesine rağmen gelir düzeyi ile sigara bırakma oranı arasında istatistiksel olarak anlamlı bir ilişki yoktur.

Tablo 17. Hastaların çocuk sayılarına göre dağılımı

Çocuk sayısı	Sayısı	Oran %	Sigara bırakma Oranı%
0	137	35.8	41.6
1	36	9.4	41.6
2-3	180	47.0	41.1
4 ve üstü	30	7.8	23.3

Hastaların çocuk sayısına göre dağılımı Tablo 17’de tanımlanmıştır. Çocuk sayısı ile sigara bırakma oranı arasında istatistiksel olarak anlamlı bir ilişki yoktur.

Tablo 18. Hastaların günlük tüketilen sigara miktarına göre dağılışı

Günlük Tüketilen Sigara Miktarı	Sayısı	Oran %	Sigara bırakma Oranı%
10 adet altı	62	16.2	32.2
10-19	203	53.0	37.4
20-29	66	17.2	56
30-39	36	9.4	38.8
40 ve üstü	16	4.2	37.5

Tablo 19. Hastaların sigara tüketimine (paket/yıl) göre dağılışı

Sigara Tüketimi (paket/yıl)	Sayısı	Oran %	Sigara bırakma Oranı%
10 adet altı	116	30.3	39.6
10-19	90	23.5	35.5
20-29	64	16.7	37.5
30-39	44	11.5	47.7
40 ve üstü	69	18.0	43.4

Hastaların Tablo 18’de günlük tüketilen sigara miktarı ve Tablo 19’da hastaların sigara tüketimi (paket/yıl) verilmiştir. Hastaların cinsiyet faktörü ile günlük tüketilen sigara miktarı ve sigara tüketimi(paket/yıl) arasında istatistiksel olarak anlamlı bir farklılık vardır ($\chi^2=7.30$; $p=0.026$). Bu farklılığın nedeni erkeklerin kadınlardan daha çok sigara tüketmesiydi. Günlük tüketilen sigara miktarı ve sigara tüketimi(paket/yıl) değişkenleri ile sigara bırakma oranı arasında istatistiksel olarak anlamlı bir ilişki yoktur.

Tablo 20. Hastaların sigaraya başlama nedenlerine göre dağılımı

Sigara Başlama Nedeni	Sayısı	Oran %
Merak	135	23.7
Çevre	47	8.3
Özenti	184	32.3
Stres	58	10.2
Arkadaş etkisi	90	15.8
Aile etkisi	55	9.7

Hastaların sigaraya başlama nedenleri Tablo 20’de gösterilmiştir. Merak ve Özenti faktörleri hastaların sigaraya başlama sebeplerinin başında gelmektedir. Sigara başlama nedenleri ile sigara bırakma oranları arasında bir ilişki tespit edilemedi.

Tablo 21. Yıllar içerisinde sigara miktarındaki değişikliklere göre dağılımı

Sigara miktarındaki değişiklikler	Sayısı	Oran %
Arttı	334	87.2
Azaldı	11	2.9
Değişmedi	29	7.6

Tablo 21’de görüldüğü gibi hastalar yıllar içinde kullanılan sigara miktarının arttığını belirttiler. Sigara miktarındaki değişiklikler ile sigara bırakma oranları arasında önemli bir fark bulunamadı.

Tablo 22. Hastaların kullandıkları sigara markasına göre dağılım

Sigara Markası	Sayısı	Oran %
LD	75	19.6
Parliament	45	11.7
Kent	30	7.8
Marlboro	28	7.3
Winston	26	6.8

Tablo 22'de hastaların %19.6'sının LD marka sigarayı tercih ettiği belirtilmektedir. Sigara markası ile sigara bırakma oranları arasında önemli bir farklılık belirlenemedi.

Tablo 23. Hastaların sigarayı bırakmayı isteme nedenlerinin dağılımı

Sigarayı bırakmayı isteme nedeni	Sayısı	Oran %
Şu anki hastalık	172	22.9
İlerde hastalık korkusu	240	32
Çevreme zarar veriyor	45	6
Ekonomik nedenler	62	8.3
Toplum baskısı	46	6.1
Utanma	37	4.9
Kokusundan	64	8.5
Doktor önerisi	19	2.5
İyi örnek olmak	33	4.4
Çocuğum zarar görmesin	21	2.8
Nefes darlığı	11	1.5

Hastaların sigarayı bırakmayı isteme nedenlerine göre dağılımı Tablo 23'de verilmiştir. Hastalar tarafından sigara bırakmayı isteme nedenlerinde şu anki hastalık ve hastalık korkusu belirtildi. Sigara bırakmayı isteme nedenleri ile sigara bırakma oranları arasında önemli bir ilişki bulunamadı.

Tablo 24. Hastaların deneme sayısına göre dağılımı

Deneme sayısı	Sayısı	Oran %
0-2	289	75.5
3-5	74	19.3
6-8	7	1.8
9 ve üstü	13	3.4

Tablo 25. Hastaların deneme süresine göre dağılımı

Deneme süresi	Sayısı	Oran %
0-3 ay	188	49.1
3-6 ay	47	12.3
6-9 ay	32	8.4
9-12 ay	18	4.7
12-18 ay	27	7.0
18-24 ay	6	1.6
24 ay üstü	47	12.3

Hastaların deneme sayısı Tablo 24’de ve deneme süreleri Tablo 25’de verilmiştir. Deneme sayısı ve deneme süresi faktörleri ile sigara bırakma oranı arasında bir ilişki tespit edilemedi.

Tablo 26. Sigarayı bıraktıklarında karşılaştığı zorluklara göre dağılımı

Sigara bırakıldığında yaşanan zorluklar	Sayısı	Oran %
Sinirlilik	194	27.3
Aşırı sigara içme isteği	171	24.1
Konsantrasyon bozukluğu	114	16
İştah artışı	47	6.6
Baş ağrısı	12	1.7
Uyku bozukluğu	85	12
Dengesizlik	16	2.3
Baş ve yüzde uyuşma	29	4.1
Kabızlık	8	1.1
Ağız yaraları	9	1.3
Zorluk yok	10	1.4
Diğer	16	2.3

Hastaların sigarayı bıraktıklarında karşılaştığı zorluklar Tablo 26’da gösterilmiştir. Hastalar sigarayı bıraktıklarında yaşadıkları zorluklar sorulduğunda en sık karşılaştıkları zorluğun sinirlilik ve aşırı sigara içme isteği olduğunu belirtmişlerdir. Hastalar sigarayı bıraktıklarında yaşadıkları zorluklar, sinirlilik ($\chi^2=40$; $p=0.03$) ve uyku bozukluğu ($\chi^2=31.3$; $p=0.01$) faktörleri sigara bırakma oranları arasında istatistiksel olarak anlamlı bir farklılık saptandı.

Tablo 27. Hastaların sigara içme isteğini arttıran nedenlere göre dağılımı

Sigara içme isteğini arttıran nedenler	Sayısı	Oran %
Yemekten sonra	220	27.9
Stres	245	31.1
Çay	180	22.8
Kahve	103	13.1
Alkol	28	3.5
Diğer	13	1.6

Hastaların sigara içme isteğini en sık artıran nedenlerin stres ve yemek sonrası olduğu Tablo 27’de verilmiştir. Hastaların sigara içme isteğini arttıran nedenler ile sigara bırakma oranları arasında anlamlı bir ilişki bulunamadı.

Tablo 28. Hastaların sistem sorgulamasındaki semptomlara göre dağılımı

Sistem sorgulaması	Sayısı	Oran %
Baş-Boyun		
Baş ağrısı	34	3.1
Göz kızarıklık	10	0.9
Diş sararma	187	17.1
Paslı dil	34	3.1
Kötü tat	149	13.6
Burun tıkanıklığı	19	1.7
Solunum Sistemi		
Öksürük	152	13.9
Balgam	141	12.9
Nefes darlığı	145	13.3
Göğüs Ağrısı	14	1.3
Kardiyovasküler Sistem		
Angina	6	0.5
Çarpıntı	48	4.4
Gastrointestinal Sistem		
Bulantı	10	0.9
Kabızlık	15	1.4
Ekşime	89	8.1
Genitoüriner Sistem		
Noktüri	12	1.1
Sinir Sistemi		
Kafa travması	28	2.6

Hastaların Tablo 28'e göre başvuru sırasında yapılan sistem sorgulamasında en sık diş sararma, öksürük ve kötü tat görüldü. Sistem sorgulamasındaki kötü tat ($\chi^2=6.07$; $p=0.009$) görülen hastaların sigara bırakma başarısında istatistiksel olarak anlamlı bir farklılık olduğu tespit edildi.

Tablo 29. Hastaların soy geçmişine göre dağılımı

Soy geçmişi	Sayısı	Oran %
Astım	14	6.4
Koah	7	3.2
Hipertansiyon	49	22.4
Dişabet	46	21
Koroner arter hastalığı	40	18.3
Konjestif kalp yetmezliği	16	7.3
Böbrek hastalığı	8	3.7
Psikolojik hastalık	4	1.8
Akciger kanseri	35	16

Hastaların soy geçmişindeki hastalıkları Tablo 29'da verilmiştir. Hastaların soy geçmişindeki hastalıkları ile sigara bırakma başarısı arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır.

Tablo 30. Hastaların özgeçmişine göre dağılımı

Özgeçmiş	Sayısı	Oran %
Astım	25	11.7
Koah	23	10.7
Hipertansiyon	50	23.4
Dişabet	26	12.1
Koroner arter hastalığı	18	8.4
Konjestif kalp yetmezliği	13	6.1
Böbrek hastalığı	4	1.9
Psikolojik hastalık	45	21
Akciğer kanseri	10	4.7

Hastaların özgeçmişindeki hastalıkları Tablo 30’da verilmiştir. Hastaların özgeçmişindeki hastalıkları ile sigara bırakma başarısı arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır.

Tablo 31. Hastaların yakın çevresinde sigara kullanılan kişilere göre dağılımı

Yakın çevre	Sayısı	Oran %
Yakın eş için	78	20.3
Yakın çocuk için	70	18
Yakın başka için	171	44.6
Yakın işyerinde için	171	44.6

Hastaların Tablo 31’e göre yakın çevresinde çocuğu, iş yerindeki arkadaşları ve çevresinde başka içinlerin olması faktörleri ile sigara bırakma oranları arasında anlamlı bir farklılık bulunamadı. Sigara bırakma başarısında eşin(partnerin) sigara kullanıp kullanmadığı istatistiksel olarak önemli olduğu saptanmıştır ($\chi^2=4.46$; $p=0.038$).

Tablo 32. Hastaların ebeveynlerinin sigara içme durumuna göre dağılımı

Anne-Baba sigara içme durumları	Sayısı	Oran %	Sigara bırakma Oranı%
Her ikisi de içmiyor	79	20.6	35.4
Baba içiyor Anne içmiyor	218	56.9	40.8
Anne içiyor Baba içmiyor	12	3.1	33.3
Her ikisi de içiyor	36	9.4	38.9
Baba içti bıraktı	35	9.1	42.8

Hastaların Tablo 32’ye göre anne ve babasının sigara kullanıp kullanmama durumu ile kişinin sigara bırakma başarısında etkili olmadığı görüldü ancak anne-baba faktörünün, baba içti bıraktı seçeneğini işaretleyen grubun sigara bırakma başarısında diğer gruplara göre daha başarılı olduğu görüldü.

Tablo 33. Hastaların hobilerine göre dağılımı

Hobiler	Sayısı	Oran %
Sosyal	51	13.3
Sanat	142	37.1
Spor	39	10.2

Hastaların Tablo 33'e göre istatistiksel olarak hastanın hobileri ile sigara bırakma oranları arasında bir farklılık görülmedi.

Tablo 34. Hastaların uygulanan tedavi yöntemine göre dağılımı

Tedavi Şekli	Sayısı	Oran %	Sigara bırakma Oranı%
Davranış tedavisi	34	8.9	38.2
Nikotin Sakızı	24	6.3	54.1
Nikotin Bandı	50	13.1	37.9
Bupropion	35	9.1	42.8
Vareniklin	37	9.7	43.2

Tablo 34'e bakıldığında sigara bırakma başarısında nikotin sakızı ile vareniklin kullanımının daha başarılı olduğu görüldü. Hastalara uygulanan tedaviler ile sigara bırakma başarısı arasında istatistiksel olarak fark olmadığı tespit edildi.

Tablo 35. Hastaların destek alma şekline göre dağılımı

Bırakma desteği	Sayısı	Oran %	Sigara bırakma Oranı%
Profesyonel Bırakma desteği (Hekim desteği)	87	22.7	55.1
Farmakolojik destek	56	14.6	39.2

Hastaların destek alma şekline göre dağılımı Tablo 35'te gösterilmiştir. Farmakolojik destek ile sigara bırakma oranı arasında bir ilişki bulunamadı. Hekimlerin gerek telefon gerek yüz yüze ilgilendikleri hastaların sigara bırakma başarısı daha yüksek olduğu istatistiksel olarak tespit edilmiştir ($\chi^2=10.8$; $p=0.039$).

Tablo 36. Hastaların Fagerst rm Nikotin Bağımlılık Testi verileri

Fagerst�rm	Sayısı	Oran %	Sigara bırakma Oranı%
Soru 1			
10 taneden az	31	8.1	32.2
11-20 tane	214	55.9	35.9
21-30 tane	82	21.4	53.6
31 ve daha fazla	56	14.6	39.2
Soru2			
1 saatten sonra	53	13.8	28.3
31-60 dakika içinde	57	14.9	45.6
6-30 dakika içinde	132	34.5	42.4
İlk 5 dakika	141	36.8	39.7
Soru3			
Yok	114	29.8	35.9
Var	269	70.2	41.6
Soru4			
Diğerleri	167	43.6	37.7
Sabah içilen ilk sigara	216	56.4	41.6
Soru5			
Yok	246	64.2	39.8
Var	137	35.8	40.1
Soru6			
Yok	56	14.6	46.4
Var	327	85.4	38.8
Nikotin Ölçeği			
Çok düşük (0-2)	32	8.4	31.2
Düşük düzey (3-4)	65	17	38.4
Orta düzey (5)	54	14.1	37
Yüksek düzey (6-7)	147	38.4	39.4
Çok yüksek düzey (8-10)	85	22.2	47

Bu veri seti için Fagerst rm Nikotin Bağımlılık Testinin sorularına verilen cevaplar Tablo 36 göz önüne alındığında test ölçümlerinin güvenilir olup olmama durumu analiz edildiğinde (Cronbach Alpha değeri 0.568) orta dereceli bir ölçek olduğu tespit edilmiştir. Soru1’de hastalara yöneltilen günde kaç sigara içiyorsunuz sorusuna verilen cevaplar ile sigara bırakma oranları arasında istatistiksel olarak anlamlı bir ilişki olduğu görülmüştür ($\chi^2=8.60$; $p=0.035$). Soru2’de hastaların sabah kalktıktan sonra ilk sigarayı içme zamanı ile sigara bırakma oranı arasında anlamlı bir farklılık bulunamadı. Hastalar soru3’te sigara içimine yasak olan yerlerde kurallara uymakta zorlandığı ifade etmişlerdir ancak soru3 ile sigara bırakma oranı arasında anlamlı bir ilişki tespit edilemedi. Hastaların soru4’te sabah içtikleri sigaradan vazgeçemediklerini belirtmişlerdir ancak soru4 ile sigara bırakma oranı arasında anlamlı bir ilişki bulunamadı. Hastalar soru5’te sigaranın günün ilk saatleri ile daha sonraki saatlere kıyasla daha sık kullanılıp kullanılmadığı sorusuna verilen cevap ile sigara bırakma arasında anlamlı bir farklılık bulunamadı. Soru6’da hastalara günün büyük bir kısmını yatakta geçirmelerine neden olacak kadar ağır hasta olmalarına rağmen sigarayı bırakmadıklarını belirtmişlerdir ancak soru6 ile sigara bırakma oranı arasında anlamlı bir farklılık tespit edilemedi. Hastaların nikotin bağımlılık düzeyi arttıkça sigara bırakma

oranının arttığı görülmektedir. Ancak Fagerstörn bağımlılık ölçek düzeyi ile sigara bırakma oranı arasında istatistiksel olarak önemli bir ilişki bulunamadı.

Tablo 37. Hastaların laboratuvar verileri

Veriler	Ortalama
Lökosit	8.71±2.02
Nötrofil	4.91±1.46
Lenfosit	2.84±0.82
Monosit	0.68±0.36
Eozinofil	0.22±0.171
Bazofil	0.047±0.03
Eritrosit	4.86±0.5
Hemoglobin	14.4±1.57
Hematokrit	42.7±4.25
Mcv	87.9±5.16
Mch	29.6±2.09
Mchc	33.6±1.1
Rdw	13.2±1.41
Trombosit	254.7±55.1
Mpv	9.5±1.39
Platelekrit	0.24±0.05
Pdw	13.02±3
Ast	21.8±8.65

Tablo 37’de verilen hastaların sigara içme eylemini sürdüren grup ile sigara içme eylemini sonlandıran grup arasında laboratuvar değerleri üzerine analiz uygulandığında; gruplar arasında lökosit ($Z=-3.09$; $p=0.002$) ve nötrofil ($Z=-0.625$; $p=0.018$) değerlerinde istatistiksel olarak anlamlı bir farklılık olduğu görülmüştür.

4.2. Lojistik Regresyon Geriye Doğru Adımsal Eleme Yöntemi Sonuçları

Bu tez çalışmasında α ’nın anlamlılık düzeyi 0.05 olarak tanımlanmıştır. Nihai modele dahil edilmek üzere aday değişkenlerin seçimi; adımsal seçim yöntemlerinden olan olabilirlik oran test istatistiklerine dayalı LR geriye doğru eliminasyon yöntemi kullanılarak elde edilmiştir. Yapılan çalışmada ilk olarak bağımsız değişkeninin her biri bağımlı değişken üzerindeki etkisi lojistik regresyon analizi ile test edilmiştir. Analiz sonucunda p-değeri 0.250’nin altında olan bağımsız değişkenler modele dahil edilmiştir. Bağımlı değişken üzerinde en az etkiye sahip olan değişkenler ($p>0.05$) her aşamada sırasıyla çıkarılmış ve son model elde edilmiştir. Son model en az değişken ile en iyi uyumu veren modeldir. Bağımsız değişkenleri içeren modelin detayları Tablo 38’de gösterilmiştir.

Tablo 38. Bağımsız değişkenleri içeren modelin özeti

Adım	Log Olabilirlik	Cox&Snell R-Square	Nagelkerke R-Square
1	361.660	0.331	0.447
17	381.870	0.294	0.398

Analiz sonucunda 17.adıma göre hastaların sigara içmeyi bırakıp bırakmamasındaki toplam değişimin 0.398'i model tarafından açıklanmaktadır. Tablo 38'e bakıldığında, log olabilirlik değerindeki bir artış, değişkenlerin uyumlu olduğunu gösterir.

Tablo 39. Eliminasyon yöntemi kullanılarak elde edilen değişkenler

17.adımın sonunda elde edilen değişkenler								
		B	S.H.	Wald	sd	p	EXP(B) (%95)	
							Lower	Upper
Adım 17	Sinirlilik	-1.899	0.276	47.431	1	0.001	0.087	0.257
	Uyku bozukluğu	-2.052	0.333	38.017	1	0.001	0.067	0.247
	Baş ağrısı	-1.44	0.514	7.86	1	0.005	0.087	0.648
	Hekim desteği	0.800	0.301	7.063	1	0.008	1.234	4.016
	Kötü tat	-0.642	0.267	5.758	1	0.016	0.312	0.889
	Lökosit	-0.177	0.087	4.142	1	0.042	0.707	0.993
	Mche	-0.313	0.162	3.717	1	0.054	0.532	1.005
	Sigara düzenli yaş	-0.05	0.026	3.624	1	0.057	0.904	1.001
	İş yerinde sigara içen	-0.963	0.516	3.486	1	0.062	0.139	1.049
	Özgeçmişinde psikolojik hastalık	0.742	0.424	3.058	1	0.08	0.914	4.826
	Soy geçmişinde diyabet hastalığı	0.634	0.38	2.784	1	0.095	0.895	3.968
	Arttıran diğer nedenler	-1.22	0.79	2.387	1	0.122	0.063	1.388
	Sabit	17.073	5.851	8.515	1	0.004	0.00	0.00

Geriye doğru eliminasyon yöntemi kullanılarak elde edilen en uygun çok değişkenli lojistik regresyon modelinde 17.adımda kalan değişkenler Tablo 39'da tanımlanmıştır. 17.adımın sonunda kalan değişkenler Wald istatistiğine göre sıralanmıştır. Wald değeri ne kadar büyükse, değişken model için o kadar önemlidir.

Tablo 40. Değişkenlerin tanımı

Uyku bozukluğu	Kategorik bir değişken olarak ifade edilen uyku bozukluğu, sigarayı bırakmada yaşanan güçlülüdür.
Sinirlilik	Kategorik bir değişken olarak ifade edilen sinirlilik, sigarayı bırakmada yaşanan güçlülüdür.
Kötü tat	Kategorik bir değişken olarak ifade edilen kötü tat, sorgulama sırasında ağızda oluşan kötü tat olup olmama durumudur.
Hekim desteği	Kategorik bir değişken olarak ifade edilen bırakma desteği, hekimlerin polikliniğe başvuran hastalarla gerek yüz yüze gerek telefonla destek olmasıdır.
İş yerinde sigara içen	Kategorik bir değişken olarak ifade edilen yakın iş yerinde sigara içen kişilerin olup olmamasıdır.
Arttıran diğer nedenler	Kategorik bir değişken olarak ifade edilen sigara içme isteğini artıran diğer nedenlerin (sevilen birini kaybetme, yalnızlık duygusu vb. gibi) var olup olmamasıdır.
Baş ağrısı	Kategorik bir değişken olarak ifade edilen baş ağrısı, sorgulama sırasında geçen süre boyunca baş ağrısının olup olmama durumudur.
Soy geçmişinde diyabet hastalığı	Kategorik bir değişken olarak ifade edilen diyabet hastalığı, hastanın soy geçmişinde diyabet hastalığı olup olmama durumudur.
Özgeçmişinde psikolojik hastalık	Kategorik bir değişken olarak ifade edilen psikolojik hastalık, Hastanın öz geçmişinde psikolojik bir hastalığının olup olmama durumudur.
Lökosit	Sürekli bir değişken olarak ifade edilen lökosit kan değeri vücudu mikropplardan, virüslerden ve diğer yabancı maddelerden koruyan bağışıklıkla ilgili beyaz kan hücreleridir.
Mchc	Sürekli bir değişken olarak ifade edilen ortalama eritrosit hemoglobin konsantrasyonu (MCHC), kırmızı kan hücrelerinde hemoglobin proteininin taşıdığı oksijen ve demir gibi moleküllerin sayısıdır. Yeterli miktarda oksijenin vücudun doku ve organlarına taşınmasında görev alır.
Sigara düzenli yaş	Sürekli bir değişken olarak ifade edilen sigara düzenli yaş, hastaların sigarayı düzenli olarak kullanmaya başladıkları yaşıdır.

Tablo 40’da değişkenlerin tanımı verilmiştir. Oluşturulan Modelin verilere uygun olup olmadığını test eden Hosmer- Lemeshow testi sonuçları Tablo 41’de verilmiştir.

Tablo 41. Hosmer Lemeshow testi

Adım	Ki-kare	Serbestlik derecesi	P değeri
1	7.013	8	0.535
17	12.646	8	0.125

Hosmer-Lemeshow test hipotezleri şu şekildedir.

H_0 : Oluşturulan model verilere uygundur

H_1 : Oluşturulan model verilere uygun değildir

Yapılan test sonucunda 0.05 anlamlılık düzeyinde p değeri 0.125 çıkmıştır. $p > 0.05$ olduğu için H_0 hipotezi red edilemez. Oluşturulan model verilere uygundur. Modelin tahmin ettiği değerler ile gözlenen değerler arasında istatistiksel olarak önemli bir fark olmadığı söylenebilir.


Tablo 42. Eliminasyon yöntemi sonucunda sınıflandırma tablosu

Tahmini Sonuçlar Gerçek Sonuçlar	Sigara içme eylemini bıraktı	Sigarayı içme eylemini bırakamadı	Doğru sınıflandırma yüzdesi
Sigara içme eylemini bıraktı	92	61	60.1
Sigarayı içme eylemini bırakamadı	39	191	83.0
Ortalama doğru sınıflandırma yüzdesi			73.9

Geriye doğru eliminasyon yöntemi kullanılarak Tablo 42’de görüldüğü üzere modelin genel olarak duyarlılığı %60.1, özgüllüğü %83 ve doğru sınıflandırma oranı %73.9’dur.

4.3. Sentetik Olarak Üretilen Verilerin Sonuçları

Veri üretmek için derin bir öğrenme tekniği kullanıldı. Üreten ağı ve Ayırt edici ağı olmak üzere iki farklı ağı kullanılmıştır. Üreten ağı gerçek verinin dağılımına uyum sağlar ve yapay veri üretilir, ayırt edici ağı ise yapay veri ile gerçek veriyi birbirinden ayırmaya çalışır. Böylece 2 farklı ağı biri yapay veri üretme konusunda uzmanlaşırken, diğeri yapay veriyi gerçek veriden ayırt etme konusunda uzmanlaşmıştır. Modele üretilecek yeterli sayıda veri örneği sağlandığında aynı veri türünden yeni örnekler oluşturulmuştur. Veri setindeki çıktıların bilinmesi ve anlaşılması, özellikle daha fazla verinin bulunması, sınıflandırma algoritmalarının karşılaştırılmasını kolaylaştırmaktadır. Bu sebeple 383 olan örnek sayısı 1000’e çıkartılmıştır. Gerçek veri ile yapay olarak oluşturulan verinin dağılımı Şekil 22’de gösterilmiştir.



Şekil 22. Gerçek veri ile yapay verinin dağılımı

Veri setinin yapısı Rstudio çıktısı olarak Şekil 23’de gösterilmiştir.

```
[1,000 x 13]
$ sinir      : num [1:1000] 0 0 0 0 1 1 1 1 0 1 ...
$ uyku       : num [1:1000] 1 0 0 0 0 0 0 1 0 1 ...
$ drDes      : num [1:1000] 0 0 0 0 0 1 0 0 1 0 ...
$ Yakinis    : num [1:1000] 1 1 1 1 1 1 1 1 1 1 ...
$ Art.Diğer  : num [1:1000] 0 0 0 0 0 0 0 0 0 0 ...
$ Basagri    : num [1:1000] 0 0 0 0 0 0 1 0 1 0 ...
$ kötütat    : num [1:1000] 1 1 0 0 1 0 1 1 0 0 ...
$ soy_Dm     : num [1:1000] 0 0 0 0 0 0 0 0 1 1 ...
$ Özpsi      : num [1:1000] 0 0 0 0 0 0 0 0 1 0 ...
$ Lökosit    : num [1:1000] 11.6 12.3 8.7 8.7 8.7 9.4 8.7 8.7 4.4 8.2 ...
$ mhc        : num [1:1000] 32.5 33.2 33.7 33.7 33.7 ...
$ Düzyas     : num [1:1000] 16 15 15 15 16 7 16 17 26 16 ...
$ bnr_dur    : num [1:1000] 1 1 0 0 1 1 1 1 1 1 ...
```

Şekil 23. Veri setinin yapısı

4.4. CNN Tabanlı Sınıflandırıcının Sonuçları

Lojistik regresyon geriye doğru eliminasyon yönteminin ardından sentetik olarak veri arttırma işleminden sonra, CNN tabanlı bir sınıflandırma algoritması geliştirmek için, her hasta için 12 parametre değeri ve sigara içme eylemini bırakıp bırakmadığından oluşan bir veri seti kullanıldı. Bu çalışmanın amacı, bireysel farklılıkları dikkate alarak, hangi parametrelerin başarılı bir şekilde sigara bırakma başarısında rol oynadığını belirlemektir. Aynı zamanda hastaların sigara bırakıp bırakamama durumu bu parametreler kullanılarak sınıflandırıldı. Derin öğrenmede en iyi sınıflandırma modelini bulmak için farklı hiperparametre değerleri (öğrenme oranı, optimizasyon yöntemi, epoch sayısı) kullanılmıştır. Modellerin sonuçları, hiperparametrelerin değerlerine bağlı olarak değişiklik göstermiştir.

Tablo 43. Öğrenme oranları karşılaştırılması

Optimizasyon yöntemi	Öğrenme Oranı	Epoch sayısı	Doğruluk Oranı (%)	Hata oranı (%)
Adam	0.1	250	68.6	0.67
Adam	0.01	250	72.4	0.58
Adam	0.001	250	79	0.51
Adam	0.0001	250	73.1	0.62

Derin öğrenme sinir ağları, stokastik gradyan iniş algoritması kullanılarak eğitilir. Stokastik gradyan inişi, eğitim veri setinden örnekler kullanarak modelin mevcut durumu için hata gradyanını tahmin eden ve ardından hataların geriye yayılması algoritmasını kullanarak modelin ağırlıklarını güncelleyen bir optimizasyon algoritmasıdır. Eğitim sırasında ağırlıkların güncellendiği miktar, adım boyutu veya "öğrenme oranı" olarak adlandırılır. Tablo 43'de sunulan öğrenme oranı bir sinir ağı modelinin bir problemi ne kadar hızlı veya yavaş öğrendiğini kontrol eder. Daha küçük öğrenme oranları, her güncellemede ağırlıklarda yapılan daha küçük değişiklikler göz önüne alındığında daha fazla eğitim dönemi gerektirirken, daha büyük öğrenme oranları hızlı değişikliklere neden olur ve daha az eğitim dönemi gerektirir. Öğrenme oranına en uygun çözüm başlangıçta öğrenme oranını yüksek tutmak ve kademeli olarak azaltmaktır. Öğrenme oranı değeri genellikle 0.01 varsayılan değeri olarak kullanılır ve belirli bir süre sonra 0.001'e düşer.

Tablo 44. Farklı optimizasyon algoritmaları karşılaştırması

Optimizasyon yöntemi	Öğrenme Oranı	Epoch sayısı	Ortalama Doğruluk Oranı(%)	Hata oranı(%)
Adam	0.01	250	79	0.51
SGD	0.01	250	78	0.52
Adadelta	0.01	250	60	0.68
RMSprop	0.01	250	78	0.67

Genel olarak Tablo 44 göz önüne alındığında aynı epoch sayısı ve aynı öğrenme oranına sahip optimizasyon algoritmaları arasında adam algoritması en iyi sonucu vermiştir.

Tablo 45. Farklı epoch değerlerinin karşılaştırılması

Epoch sayısı	Ortalama Doğruluk Oranı (%)	Hata oranı (%)
50	75	0.58
100	77	0.56
250	79	0.51
1000	67	1.77

Tablo 45'te görüldüğü gibi epoch sayısı 250 seçildiğinde modelimiz en iyi sonuçları vermektedir. Her model için optimum bir epoch sayısı vardır. Epoch sayısı optimum değerine yaklaştıkça hata oranı azalır, optimum değerinden uzaklaştıkça hata oranı artar. Farklı hiperparametreler için oluşturulan modellerin sonuçları Tablo 46'da gösterilmiştir.

Tablo 46. Sistemi eğitirken farklı hiperparametreler için oluşturulan modeller


Model	Epoch sayısı	Batch boyutu	Optimizasyon yöntemi	Doğruluk oranı	Hata oranı
1. Model	50	32	Rmsprop	72	0.80
2. Model	50	32	Adam	75	0.58
3. Model	50	32	Sgd	74	0.62
4. Model	50	32	Adadelta	59	0.84
5. Model	100	32	Rmsprop	77	0.66
6. Model	100	32	Adam	77	0.56
7. Model	100	32	Sgd	76	0.74
8. Model	100	32	Adadelta	60	0.92
9. Model	250	32	Rmsprop	78	0.67
10. Model	250	32	Adam	79	0.51
11. Model	250	32	Sgd	78	0.52
12. Model	250	32	Adadelta	60	0.68
13. Model	1000	32	Rmsprop	65	1.92
14. Model	1000	32	Adam	67	1.77
15. Model	1000	32	Sgd	64	2.08
16. Model	1000	32	Adadelta	52	4.22

Tablo 46, bir bütün olarak ele alındığında, hiperparametre seçme sürecinde; belirtilen aralıktaki tüm değerlerin kombinasyonları için ağ eğitilir, sonuçlar gözlemlenir ve en az hata oranına sahip kombinasyon hiperparametre grubu olarak belirlenir.

Tablo 47. En başarılı modelin detayları


Optimizasyon	Öğrenme Oranı	Epoch sayısı	Doğruluk Oranı(%)	Hata oranı(%)
Adam	0.001	250	79	0.51

En iyi CNN modeli Tablo 47’de gösterildiği gibi elde edilmiştir. En iyi modele ait grafikler aşağıda verilmiştir. Eğitim ve test doğruluğunu gösteren grafik Şekil 24’te gösterilmiştir.




Şekil 24. Eğitim ve test doğruluk grafiği

Eğitim ve test hatasını gösteren grafik Şekil 25’te gösterilmiştir.




Şekil 25. Eğitim ve test hata grafiği

Eğitim ve doğrulama doğruluğunu gösteren grafik Şekil 26’da gösterilmiştir.



Şekil 26. Eğitim ve doğrulama doğruluk grafiği

Eğitim ve doğrulama hatasını gösteren grafik Şekil 27’de gösterilmiştir.



Şekil 27. Eğitim ve doğrulama hata grafiği

Şekil 27'de gösterilen model eğitim(train) ve doğrulama(validation) hatası grafiği(loss), öğrenme eğrisi olarak da adlandırılır. Öğrenme eğrisinden eğitim hatasının doğrulama hatasından daha küçük olduğu tespit edildi. Bu kapsamda, eğitim hatası ile doğrulama hatası arasında belirli bir boşluk olması gerekmektedir. Sonuç olarak, model iyi bir uyum göstermiştir.

Tablo 48. En başarılı model için 5 kat çapraz doğrulama

	Doğruluk Oranı (%)	Hata oranı (%)
1.kat	79	0.52
2.kat	76	0.68
3.kat	77	0.65
4.kat	77	0.67
5.kat	79	0.50
Ortalama	77.6	0.6

Çapraz doğrulama sonuçları Tablo 48’te gösterilmiştir. En başarılı model için 5 kat çapraz doğrulama her kat için 250 epoch ile çalıştırıldı. En başarılı modelin karışıklık matrisi sonuçları Tablo 49’da gösterilmiştir.

Tablo 49. En başarılı modelin karışıklık (confusion) matrisi sonuçları

Tahmini Sonuçlar	Sigara içme eylemini bıraktı	Sigarayla içme eylemini bırakmadı
Gerçek Sonuçlar		
Sigara içme eylemini bıraktı	51(TP)	29(FN)
Sigarayla içme eylemini bırakmadı	14(FP)	106(TN)

Tablo 50’de sınıflandırıcı metrikleri ifade edilmiştir.

Tablo 50. Sınıflandırıcı metrikleri

Metrik Adı	Tanımı
Accuracy (Doğruluk)	Accuracy (Doğruluk) değeri, modelde doğru şekilde tahmin edilen verilerin tüm veri kümesine oranı olarak hesaplanır. $(TP+TN)/(TP+TN+FN+FP)$
Duyarlılık (Sensitivity)	Sınıflandırıcının duyarlılığı, kaç tanesinin doğru olarak pozitif olarak tanımlandığı ile kaçının gerçekte pozitif olduğu arasındaki orandır. $(TP/(FN+TP))$
Özgüllük (Specificity)	Sınıflandırıcının özgüllüğü, kaç tanesinin doğru olarak negatif olarak sınıflandırıldığı ile kaçının gerçekte negatif olduğu arasındaki orandır. $(TN/(FP+TN))$
Kesinlik (Precision)	Tüm pozitiflerden kaç tanesi doğru olarak pozitif olarak sınıflandırıldı. $(TP/(TP+FP))$
Geri Çağırma (Recall)	Geri çağırma (Recall) ve duyarlılık (Sensitivity) aynı anlama gelen bir metriktir. $(TP/(FN+TP))$
F1 puanı (F1 score)	F1 Skoru, kesinlik ve geri çağırma değerlerinin harmonik ortalamasını gösterir. $F1=2x (Kesinlik \times Geri \text{ Çağırma}) / (Kesinlik+Geri \text{ Çağırma})$

Buna göre 200 test verisi üzerinde geliştirilen en iyi CNN modeli için %64 duyarlılık, %88 özgüllük ve %79 doğruluk değerleri elde edilmiştir. Sınıflandırıcı model çıktıları Tablo 51’de ifade edilmiştir.

Tablo 51. Sınıflandırıcı model çıktıları

	Kesinlik (Precision)	Geri Çağırma (Recall)	F1 puanı (F1-score)	Örnek (Support)
Sınıf bıraktı	0.78	0.64	0.70	80
Sınıf bırakmadı	0.79	0.88	0.83	120
Doğruluk	0.79	0.79	0.79	200
Makro ortalama	0.78	0.76	0.77	200
Ağırlıklı Ortalama	0.78	0.79	0.78	200

Sınıflandırıcı modelin sonuçları incelendiğinde, sigarayı bırakamayan hastalarda örneklem sayısının daha fazla olması nedeniyle modelin sigarayı bırakamayan hastaları bırakan hastalara göre daha başarılı bir şekilde ayırdığı görüldü.

Tablo 52. Veri seti için sınıflandırıcıların karşılaştırılması

Sınıflandırıcı	Doğruluk	Recall (Geri Çağırma)	Precision (Kesinlik)
LR	0.77	0.75	0.76
RF	0.78	0.76	0.77
KNN	0.73	0.72	0.73
SVM	0.78	0.76	0.77
NB	0.76	0.74	0.74
KA	0.78	0.74	0.78
MLP	0.79	0.74	0.78
CNN	0.79	0.76	0.78

Genel olarak sınıflandırıcıların makro ortalamaları göz önüne alınarak oluşturulan Tablo 52’den görüleceği üzere, bu veri seti için sınıflandırma algoritmalarından derin öğrenme yöntemlerinden CNN ve MLP sınıflandırma algoritmaları, geleneksel makine öğrenmesi algoritmalarına göre başarılı sonuçlar vermiştir. CNN ve MLP sınıflandırıcı algoritmaları aynı doğruluk değerine sahip olsa da CNN yöntemi ortalama geri çağırma ve ortalama kesinlik açısından daha kullanışlı bir sınıflandırma algoritması olduğunu kanıtlamıştır.

CNN tabanlı sınıflandırıcı kullanılarak lojistik regresyon geriye doğru eleme yöntemiyle her bir adımda atılan değişkenden sonra modelde kalan değişkenlerin sınıflandırma hata oranları Tablo 53’de sunulmuştur.

Tablo 53. Sınıflandırma hata oranları

Adım Sayısı	Test hata oranı
1.adım	0.81
2.adım	0.66
3.adım	1.26
4.adım	0.98
5.adım	0.73
6.adım	1.25
7.adım	0.66
8.adım	1.71
9.adım	1.02
10.adım	0.85
11.adım	0.78
12.adım	0.67
13.adım	0.72
14.adım	0.69
15.adım	0.79
16.adım	0.66
17.adım	0.51

Lojistik regresyon geriye doğru eleme yönteminin her adımı, CNN sınıflandırıcı ile test edilmiş ve en düşük hata oranının 17. adımda elde edildiği sonucuna ulaşılmıştır.

5. TARTIŞMA ve SONUÇ

Yapay zekanın hayatımızın her alanında olduğu gibi tıp alanında kullanımı gittikçe yaygınlaşmaktadır. ML, özellikle DL yöntemleri, hastalıkların teşhisinde önemli ilerlemeler kaydetmiştir. AI sistemleri, hekimlere yardımcı olmak için verilerden bilgileri çıkartır ve analiz eder. Uzman sistemden elde edilen istatistiksel bilgiler doğrultusunda kişiye özel tedavi planı sunduğu için hekimin karar vermesinde etkilidir. Makine öğrenimi algoritmaları, hekimlerin yaptığı gibi belirli kalıpları görmeyi öğrenir. Tek fark, algoritmayı eğitmek için çok fazla doğru veri gerektirmesidir. AI tabanlı sistemlerin hedeflerinden biri de tedavi de başarının artırılabilmesini sağlamak amacıyla hekimlere rehberlik etmektir.

Derin öğrenme yöntemlerden biri olan en başarılı CNN sınıflandırma modelini tasarlamak için çeşitli aktivasyon ve optimizasyon yöntemleri, farklı öğrenme oranları ve epoch sayıları kullanılmıştır. Model sonuçları parametrelere göre değişiklik göstermiştir. Modeller, SGD, Adadelta, Adam ve RMSprop optimizasyon yöntemleri kullanılarak oluşturulduğunda, bu veri seti için en yüksek başarı oranına sahip yöntemin Adam olduğu belirlendi. Adam optimizasyon yönteminin diğer optimizasyon yöntemlerinden farkı, her parametre için öğrenme oranını koruması ve gradyan problemini çözerken performansı arttırmasıdır. CNN ile yapılan çalışmalarda, modellerin performansının, kullanılan veri setinin yapısı, boyutu, optimizasyon teknikleri ve aktivasyon fonksiyonlarına bağlı olarak değiştiği belirlenmiştir.

Sigarayı bırakma tedavisi zorlu ve zaman alıcı bir iştir. Tedavi süresi kişiden kişiye farklılık göstermektedir. Sigara bağımlılığının bilişsel, davranışsal ve fizyolojik yönleri incelendiğinde oldukça çeşitli etkilerine rastlanmaktadır. Hekimlerin tüm bu etkileri değerlendirmesinde ve en uygun tedaviyi planlamasında bireysel farklılıkları göz önüne alması gerekmektedir. Bu bağlamda, sigarayı bırakmak için yeni yaklaşımlar ve düzenlemeler kaçınılmaz bir gereklilik haline geldiği düşünülmüştür.

KTÜ Farabi Hastanesi Göğüs Hastalıkları Anabilim Dalı Sigara Bırakma Polikliniğine başvurmuş 383 hasta verisi kullanılmıştır. Sigara içme eylemini sonlandıran hastalar %40(153), sigara içme eylemini devam ettiren hastaların oranı %60(230) tır. 383 hasta verisine lojistik geriye doğru eliminasyon adımsal seçim yöntemlerinden, olabilirlik oran test istatistiği uygulandığında sigara bırakma başarısında etkili olan 12 faktör tespit edilmiştir. Derin öğrenme yaklaşımının bir yöntemi olan konvolüsyonel sinir ağı (CNN)

sınıflandırıcısı olan model yapısı, bireysel farklılıklara dayalı olarak sigara içme oranını tahmin etmek için geliştirilmiştir. CNN tabanlı karar destek sistemi, 383 hasta verisinden elde edilen 12 faktörden oluşan bir veri seti kullanılarak geliştirilmiştir. Bu çalışmada veri artırma tekniği uygulanarak 383 olan örneklem sayısı 1000 örnekleme yükseltilmiştir. Bu parametrelere ait veri setindeki 1000 örneklemin 800'ü eğitim 200'ü test seti olmak üzere rastgele ayrılmıştır. 800 gözlem değerinden oluşan eğitim setimizde 480 hasta sigarayı bırakmadı ve 320 hasta sigarayı bırakmıştı. 200 gözlem değerinden oluşan test setimiz, 80 hasta sigarayı bıraktı, 120 hasta sigarayı bırakmadı. Tüm veri setinin %20'si doğrulama seti olarak kullanılmıştır. Geliştirilen konvolüsyonel sinir ağı (CNN), 200 test verisi üzerinde %64 duyarlılık, %88 özgüllük ve %79 doğruluk değerleri elde etmiştir.

Literatürdeki benzer çalışmalara bakıldığında, Coughlin ve arkadaşları tarafından 2018 yılında yayınlanan bir çalışmada grup bilişsel-davranışçı terapi (CBT) gören 161 sigara kullanan hastalar iki gruba ayrıldı. 161 kişinin 90'ı eğitim verisi ve 71'i doğrulama verisi olarak ayrıldı. Hastaların sigarayı bırakma durumlarını tahmin etmek için önemli faktörler belirlendi. Bırakma sonuçlarını tahmin etmek için makine öğrenimi ile geliştirilen bir karar ağacı modeli kullanıldı. Karar ağacı modeli ile yaklaşık %64'lük bir ortalama doğru sınıflandırma oranını tahmin edebilen bir karar destek sistemi geliştirilmiştir (9). Kharabsheh M. ve arkadaşları tarafından 2019 yılında yapılan bir çalışmada yaş, ikamet ve eğitim düzeyi gibi sigara içenlerle ilgili 19 faktör kullanılarak 108 Ürdün'lü tütün kullanan kadınlar için nikotin bağımlılık düzeyini tahmin eden bir sınıflandırıcı geliştirilmiştir. Sınıflandırıcı farklı faktör grubu kombinasyonlarının performansını değerlendirmek için dört grupta incelenmiştir. Destek vektör makinesi, Naive Bayes, en yakın komşuluk ve karar ağaçları sınıflandırıcıları olmak üzere 4 farklı sınıflandırıcı geliştirilmiştir. Destek vektör makinesi %82 duyarlılık ve %43 özgüllük değeri ile sonucu en başarılı tahmin edebilen bir karar destek sistemi geliştirilmiştir (10). C.C. Lai ve arkadaşları tarafından 2021 yılında yayınlanan bir çalışmada Kuzey Tayvan'daki bir tıp merkezinde 4875 hastanın katılımıyla sigara bırakmanın sonucunu tahmin etmek için bir model geliştirildi. 4375 eğitim verisi ve 500 test verisi olmak üzere ikiye ayrılmıştır. Hasta verileri, Yapay sinir ağı (YSA), destek vektör makinesi (SVM), rastgele orman (RF), lojistik regresyon (LR), k-en yakın komşu (KNN) ve saf Bayes (NB) olmak üzere farklı sınıflandırıcılar kullanılarak eğitildi. Yapay sinir ağı (YSA) algoritması, %70 duyarlılık, %56 özgüllük ve %64 doğruluk oranı ile sonucu en başarılı tahmin edebilen karar destek sistemi geliştirilmiştir (11).

Literatürdeki benzer çalışmalarla karşılaştırıldığında, çalışmaların benzer ve farklı yönleri bulunmaktadır. Coughlin (9) ve Kharabsheh M. (10) gerçekleştirdiği çalışmalarında yaş faktörü ile sigara bağımlılığı arasında bir ilişki olduğunu tespit etmiştir. Lai (11) gerçekleştirdiği çalışmasında yaş ile sigara bağımlılığı arasında bir bağlantı olmadığını ifade etmiştir. Bu çalışma, Lai'nin çalışmasını destekler niteliktedir ancak düzenli olarak sigara kullanmaya başlama yaşı ile sigara bırakma arasında güçlü bir ilişki olduğu tespit edilmiştir. Lai (11) gerçekleştirdiği çalışmasında hekim desteği ile sigara bırakmayı kolaylaştırma açısından bir farklılık olmadığını belirtmiştir. Bu çalışmada kişilerin bırakma başarısında hekimlerin rol oynadığı güçlü bir şekilde tespit edilmiştir. Bu çalışmada en özgün yanlarından biridir. Yapılan çalışmalar (9, 11) hastaların cinsiyet, gelir düzeyi ve eğitim durumu ile ilgili sigara bırakmada anlamlı bir farklılık göstermediğini ifade etmiştir. Bu çalışmada yapılan çalışmaları destekler niteliktedir. Bu çalışmaya benzer şekilde Lai (11) gerçekleştirmiş olduğu çalışmasında sigara içme süresi ile sigara bırakma başarısı arasında anlamlı bir farklılık olmadığını göstermiştir. Bu çalışmaya benzer olarak yapılan çalışmalar (9, 11) Fagerstörn nikotin bağımlılık ölçeğinin yüksek ya da düşük çıkmasının sigara bırakma başarısında anlamlı bir faktör olmadığını ifade etmişlerdir. Bu çalışmada olduğu gibi Lai (11) gerçekleştirmiş olduğu çalışmasında tedavi sırasında ilaç kullanımının sigarayı bırakmada anlamlı bir farklılık göstermediğini saptamıştır. Diğer çalışmalardan (9, 10, 11) farklı olarak bir kişide yalnızlık hissetme, sevilen birini kaybetme vb. gibi sigara içme eylemini arttıran (diğer nedenler) psikolojik değişiklikler sigara içme eylemini arttıran bir faktör olarak sigara bırakma başarısında etkili olduğu görülmüştür. Yine diğer çalışmalardan (9, 10, 11) farklı olarak çalışmamızda ailede diyabet hastalığının varlığı sigara bırakma başarısında bir faktör olduğu belirlendi. Diğer çalışmalardan (9, 10, 11) farklı olarak sigara bırakmayı zorlaştıran nedenlerden sinirlilik ve uyku bozukluğu faktörleri ile sigara bırakma başarısı arasında güçlü bir ilişki olduğu tespit edildi. Bu çalışmada duyarlılık, sigarayı bırakan kişilerin öngörücü değerini, özgüllük ise sigarayı bırakmayan kişilerin öngörücü değerini göstermiştir. Sigarayı bırakamayan kişilerin sayısı fazla olduğu için sistem sigarayı bırakamayan kişileri tahmin etmede daha başarılı olmuştur. Bu tahmin modelinin 10 bin ve üstünde gözlem değerine sahip olması durumunda performansın daha iyi olması beklenmektedir. Tüm bunlar değerlendirildiğinde yapılan çalışmalar arasında bu çalışma %64 duyarlılık, %88 özgüllük ve %79 doğruluk değerleri ile konvolüsyonel sinir ağları ile geliştirilmiş olması bu çalışmanın özgün yanlarından biridir.

Geleneksel makine öğrenmesi ile derin öğrenme yöntemlerini karşılaştırmak için, lojistik regresyon geriye doğru eleme yöntemi kullanılarak 17.adımda 12 öznelik belirlendi. Çalışmamızda CNN sınıflandırıcısı, lojistik regresyon geriye doğru eliminasyon yönteminin her adımında atılan değişkenin bizim için anlamlı olup olmadığını test etmek için her adımdan sonra kalan değişkenleri model veri seti olarak kullanmıştır. Sistem sonuçları 17. adımın en düşük hata oranına sahip olduğunu göstermiştir. Lojistik regresyon geriye doğru eleme yöntemi öznelik seçiminde başarılı bulunmuştur.

Literatürde demografik veriler kullanılarak oluşturulan sınıflandırma algoritmaları arasında geleneksel makine yöntemlerinin özellikle rastgele orman (RF) sınıflandırıcısının derin öğrenme yöntemlerinden daha başarılı olduğu görülmüştür (128, 129). Bu çalışmada derin öğrenme yöntemlerinden biri olan konvolüsyonel sinir ağı (CNN), rastgele orman sınıflandırıcısından daha iyi performans göstermiştir ve bu çalışmanın özgün yönlerinden biridir. Bu bağlamda bu tez çalışması demografik verileri sınıflandırmak için bir CNN sınıflandırıcı önermektedir.

Geliştirilen karar destek sistemi dünyada ve ülkemizde sigara bırakma polikliniğine başvuran hastaların sigara düzeylerini sınıflayarak hekimlere tedavi sürecini belirlemede yardımcı olacağı düşünülmektedir. Bu konuda ileride geliştirilebilecek farklı bilimsel çalışmalara ışık tutması beklenmektedir. Bununla birlikte gelecek çalışmalarda CNN ağının başarısının artırılabilmesi için klinik verilerin genetik verilerle desteklenerek daha sağlam bir karar destek sistemi geliştirilmesi hedeflenmektedir.

6. KAYNAKLAR

1. Webber BL, Nilsson NJ (2014). Readings in artificial intelligence. Morgan Kaufmann. California; Sayfa: 201-272.
2. Alpaydin E (2020). Introduction to machine learning. Massachusetts Institute of Technology (MIT) Press. Cambridge; Sayfa: 60-67.
3. Goodfellow I, Bengio Y, Courville A (2016). Deep learning. Massachusetts Institute of Technology (MIT) Press. London; Sayfa: 136-151.
4. Kim Y (2014). Convolutional neural networks for sentence classification. [online]. Available from: <https://arxiv.org/pdf/1408.5882.pdf>. [Accessed 6 Jan 2021].
5. Collobert R, Weston J (2008). A unified architecture for natural language processing: Deep neural networks with multitask learning. Proceedings of the 25th International Conference on Machine learning, 160–167.
6. Sipes R, Li D (2018). Using convolutional neural networks for automated fine grained image classification of acute lymphoblastic leukemia. 3rd International Conference on Computational Intelligence and Applications, 157–161.
7. Das S, Aranya OFMRR, Labiba NN (2019). Brain tumor classification using convolutional neural network. 1st International Conference on Advances in Science, Engineering and Robotics Technology, 1–5.
8. Caponnetto P, Polosa R (2008). Common predictors of smoking cessation in clinical practice. Respiratory Medicine 102: 1182–1192.
9. Coughlin LN, Tegge AN, Sheffer CE, Bickel WK (2020). A machine-learning approach to predicting smoking cessation treatment outcomes. Nicotine and Tobacco Research 22: 415–422.
10. Kharabsheh M, Meqdadi O, Alabed M, Veeranki S, Abbadi A, Alzyoud S (2019). A machine learning approach for predicting nicotine dependence. International Journal of Advanced Computer Science and Applications 10: 179–184.
11. Lai CC, Huang WH, Chang BCC, Hwang LC (2021). Development of machine learning models for prediction of smoking cessation outcome. International Journal of Environmental Research and Public Health 18: 1–10.
12. Organization WH. (2020). Tobacco. World Health Organization. WHO, New York.
13. Organization WH (1997). Tobacco or health: a global status report. World Health Organization. WHO, New York.

14. Organization WH (2011). WHO report on the global tobacco epidemic. Warning about the dangers of tobacco: Executive summary Geneva: World Health Organization. WHO, New York.
15. Barış İ (2013). Tütün kullanımının tarihçesi. Türk Toraks Derneği [online]. Available from: www.toraks.org.tr/userfiles/file/tutunkullaniminintarihcesibaris.pdf. [Accessed 7 Oct 2020].
16. Gately I (2007). Tobacco: A cultural history of how an exotic plant seduced civilization. Grove Press, New York, Sayfa: 11-15.
17. Holmes GK (1923). Some features of tobacco history. Agricultural History Society 2: 385–407.
18. Gately I (2002). La diva nicotina: The story of how tobacco seduced the world. Scribner. Simon and Schuster, London, Sayfa: 20-31.
19. Uzunca G (2002). Tütünün Tarihçesi. Sigara ve Sağlık, Uludağ Üniversitesi Basımevi, Bursa, Sayfa: 21-28.
20. Glantz SA, Slade J, Bero LA, Hanauer P, Barnes DE (1998). The cigarette papers. University of California Press, Sayfa: 117-145.
21. Mackay J, Eriksen M, Eriksen MP (2002). The tobacco atlas. World Health Organization, 1. Baskı, Geneva, Sayfa: 24-30.
22. Peçevî İ (1968). Peçevî tarihi. Ed. Murat Uraz, Neşriyat Yurdu, İstanbul, Sayfa: 23-25.
23. Karadağ M, Bilgiç H (2010). Tütün ve tütün kontrolü. Türk Toraks Derneği Kitapları, Sayfa: 52-80.
24. Organization WH (2019). WHO report on the global tobacco epidemic, 2019: Offer help to quit tobacco use, World Health Organization. WHO, New York.
25. Organization WH (2010). Global Adult Tobacco Survey: Turkey report 2008. WHO, New York.
26. Karlıkaya C, Öztuna F, Solak ZA, Özkan M, Örsel O (2006). Tütün kontrolü. Türk Toraks Dergisi 7: 51–64.
27. Malaiyandi V, Sellers EM, Tyndale RF (2005). Implications of CYP2A6 genetic variation for smoking behaviors and nicotine dependence. Clinical Pharmacology & Therapeutics 77: 145–158.
28. Tutka P, Mosiewicz J, Wielosz M (2005). Pharmacokinetics and metabolism of nicotine. Pharmacol Reports 57: 143–153.

29. Üneri Ö, Tural Ü, Memik NÇ (2006). Şizofreni ve sigara içimi: Biyolojik bağlantı nerede. *Türk Psikiyatri Dergisi* 17: 55–64.
30. Kayaalp OS (2005). Rasyonel tedavi yönünden Tıbbi Farmakoloji. 9. Baskı, Hacettepe Cilt 2: 1252–1264.
31. Russell MA, Jarvis MJ, Devitt G, Feyerabend C (1981). Nicotine intake by snuff users. *British Medical Journal* 283: 814–817.
32. Demir T, Tıp İÜCTFS, Etkinlikleri (2008). Sigara Bağımlılığı. Türkiye’de Sık Karşılaşılan Psikiyatrik Hastalıklar. Sempozyum Dizisi 62: 231-238.
33. Heatherton TF, Kozlowski LT, Frecker RC, Fagerstrom K (1991). The Fagerström test for nicotine dependence: a revision of the Fagerstrom tolerance questionnaire. *British Journal of Addiction* 86: 1119–1127.
34. Uysal MA, Kadakal F, Karşıdağ C, Bayram NG, Uysal O, Yılmaz V (2004). Fagerstrom test for nicotine dependence: reliability in a Turkish sample and factor analysis. *Tuberk Toraks* 52: 115–121.
35. Meneses-Gaya IC, Zuairi AW, Loureiro SR, Crippa JA (2009). Psychometric properties of the Fagerström test for nicotine dependence. *Jornal Brasileiro de Pneumologia* 35: 73–82.
36. Bao Y, Duan N, Fox SA (2006). Is some provider advice on smoking cessation better than no advice? An instrumental variable analysis of the 2001 national health interview survey. *Health Services Research* 41: 2114–2135.
37. Çalışma Türk Toraks Derneği (2014). Sigara bırakma tanı ve tedavi uzlaşısı raporu. Ankara, Sayfa: 17-24.
38. Hurt RD, Sachs DPL, Glover ED, Offord KP, Johnston JA, Dale LC, Khayrallah MA, Schroeder DR, Glover PN, Sullivan CR (1997). A comparison of sustained-release bupropion and placebo for smoking cessation. *New England Journal of Medicine* 337: 1195–1202.
39. Jorenby DE, Leischow SJ, Nides MA, Rennard SI, Johnston JA, Hughes AR, Smith SS, Muramoto ML, Daughton DM, Doan K (1999). A controlled trial of sustained-release bupropion, a nicotine patch, or both for smoking cessation. *New England Journal of Medicine* 340: 685–691.
40. Simon JA, Duncan C, Carmody TP, Hudes ES (2004). Bupropion for smoking cessation: a randomized trial. *Archives of Internal Medicine* 164: 1797–1803.

41. Gonzales D, Rennard SI, Nides M, Oncken C, Azoulay S, Billing CB, Watsky EJ, Gong J, Williams KE, Reeves KR (2006). Varenicline, an $\alpha 4\beta 2$ nicotinic acetylcholine receptor partial agonist, vs sustained-release bupropion and placebo for smoking cessation: a randomized controlled trial. *The Journal of the American Medical Association* 296: 47–55.
42. Jorenby DE, Hays JT, Rigotti NA, Azoulay S, Watsky EJ, Williams KE, Billing CB, Gong J, Reeves KR, Group VP 3 S (2006). Efficacy of varenicline, an $\alpha 4\beta 2$ nicotinic acetylcholine receptor partial agonist, vs placebo or sustained-release bupropion for smoking cessation: a randomized controlled trial. *The Journal of the American Medical Association* 296: 56–63.
43. Nides M, Oncken C, Gonzales D, Rennard S, Watsky EJ, Anziano R, Reeves KR, Group VS (2006). Smoking cessation with varenicline, a selective $\alpha 4\beta 2$ nicotinic receptor partial agonist: results from a 7-week, randomized, placebo-and bupropion-controlled trial with 1-year follow-up. *Archives of Internal Medicine* 166: 1561–1568.
44. Kleinbaum DG, Klein M (2010). *Logistic regression: A self-learning text*. Springer Science and Business Media, New York; Sayfa: 161-226.
45. Hosmer Jr DW, Lemeshow S, Sturdivant RX (2013). *Applied logistic regression* (Vol. 398), John Wiley & Sons, Sayfa: 270-305.
46. Özdamar K (2004). *Paket programlar ile istatistiksel veri analizi (çok değişkenli analizler)*. Kaan Kitabevi, Eskişehir; Sayfa: 22-23.
47. Bircan H (2004). *Lojistik regresyon analizi: Tıp verileri üzerine bir uygulama*. Kocaeli Üniversitesi Sosyal Bilimler Dergisi 185–208.
48. Peng C-YJ, Lee KL, Ingersoll GM (2002). An introduction to logistic regression analysis and reporting. *The Journal of Educational Research* 96: 3–14.
49. Alpar R (2011). *Uygulamalı çok değişkenli istatistiksel yöntemler*. Detay Yayıncılık, Ankara; Sayfa: 201-296.
50. Tranmer M, Elliot M (2008). Binary logistic regression. *Cathie Marsh for Census and Survey Research* 20: 3–42.
51. Buaya S, Tongkumchum P, Owusu BE (2020). Modelling of land-use change in Thailand using binary logistic regression and multinomial logistic regression. *Arabian Journal of Geosciences* 13: 1–12.

52. Stewart G, Kamata A, Miles R, Grandoit E, Mandelbaum F, Quinn C, Rabin L (2019). Predicting mental health help seeking orientations among diverse Undergraduates: An ordinal logistic regression analysis. *Journal of Affective Disorders* 257: 271–280.
53. Palazon-Bru A, Folgado-de la Rosa DM, Cortes-Castell E, Lopez-Cascales MT, Gil-Guillen VF (2017). Sample size calculation to externally validate scoring systems based on logistic regression models. *Public Library of Science* 12: e0176726.
54. Menard S (2000). Coefficients of determination for multiple logistic regression analysis. *The American Statistician* 54: 17–24.
55. Hongyue W, Jing P, Bokai W, Xiang LU, Julia ZZ, Kejia W, Xin M, Changyong F (2017). Inconsistency between univariate and multiple logistic regressions. *Shanghai Archives of Psychiatry* 29: 124.
56. Şenel S, Alatlı B (2014). Lojistik regresyon analizinin kullanıldığı makaleler üzerine bir inceleme. *Journal of Measurement and Evaluation in Education and Psychology* 5: 35–52.
57. Hsieh FY, Bloch DA, Larsen MD (1998). A simple method of sample size calculation for linear and logistic regression. *Statistics in Medicine* 17: 1623–1634.
58. Miller T (2019). Explanation in artificial intelligence: Insights from the social sciences. *Artificial Intelligence* 267: 1–38.
59. Russell S, Norvig P (2010). *Artificial intelligence: A modern approach*. Prentice Hall, New Jersey, Sayfa: 650-780.
60. Mitchell TM (1997). *Artificial neural networks, Machine learning*. Burr Ridge, McGraw Hill, 45: 81–127.
61. Raschka S, Mirjalili V (2017). *Python Machine Learning: Machine Learning and Deep Learning with Python. Scikit-Learn, and TensorFlow* Second edition ed.
62. Albayrak AS, Yilmaz SK (2009). Veri madenciliği: Karar ağacı algoritmaları ve imkb verileri üzerine bir uygulama. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, Cilt:14, Sayı:1, Sayfa: 31-52.
63. Sra S, Nowozin S, Wright SJ (2012). *Optimization for machine learning*. Massachusetts Institute of Technology (MIT) Press, London, Sayfa: 191-197.
64. Bonaccorso G (2017). *Machine learning algorithms*. Packt Publishing Ltd., Birmingham; Sayfa: 24-27.

65. Gavrilov AD, Jordache A, Vasdani M, Deng J (2018). Preventing model overfitting and underfitting in convolutional neural networks. *International Journal of Software Science and Computational Intelligence (IJSSCI)* 10: 19–28.
66. Xiong Z, Cui Y, Liu Z, Zhao Y, Hu M, Hu J (2020). Evaluating explorative prediction power of machine learning algorithms for materials discovery using k-fold forward cross-validation. *Computational Materials Science* 171: 109203.
67. Belkin M, Hsu D, Ma S, Mandal S (2019). Reconciling modern machine-learning practice and the classical bias–variance trade-off. *Proceedings of The National Academy of Sciences* 116: 15849–15854.
68. Estabrooks A, Jo T, Japkowicz N (2004). A multiple resampling method for learning from imbalanced data sets. *Computational Intelligence* 20: 18–36.
69. Vellido A, Martin-Guerrero JD, Lisboa PJG (2012). Making machine learning models interpretable. *European Symposium On Artificial Neural Networks, Computational Intelligence and Machine Learning (ESANN)* 12: 163–172.
70. Balaban ME, Kartal E (2015). Veri madenciliği ve makine öğrenmesi temel algoritmaları ve r dili ile uygulamaları. Çağlayan Kitabevi, İstanbul; Sayfa: 30-33.
71. Priyam A, Abhijeeta GR, Rathee A, Srivastava S (2013). Comparative analysis of decision tree classification algorithms. *International Journal of Current Engineering and Technology* 3: 334–337.
72. Su J, Zhang H (2006). A fast decision tree learning algorithm. *Association for The Advancement of Artificial Intelligence (Aaai)* 6: 500–505.
73. Imandoust SB, Bolandraftar M (2013). Application of k-nearest neighbor (knn) approach for predicting economic events: Theoretical background. *International Journal of Engineering Research and Applications* 3: 605–610.
74. Soucy P, Mineau GW (2001). A simple KNN algorithm for text categorization. *Proceedings 2001 IEEE International Conference on Data Mining*, 647–648.
75. Steinbach M, Tan PN (2009). KNN: K-nearest neighbors. *The top ten algorithms in data mining*. Chapman and Hall 2: 165–176.
76. Liaw A, Wiener M (2002). Classification and regression by random forest. *Reddit News* 2: 18–22.
77. Strobl C, Malley J, Tutz G (2009). An introduction to recursive partitioning: rationale, application, and characteristics of classification and regression trees, bagging, and random forests. *Psychological Methods* 14: 323.

78. Masetic Z, Subasi A (2016). Congestive heart failure detection using random forest classifier. *Computer Methods and Programs in Biomedicine* 130: 54–64.
79. Pal M (2005). Random forest classifier for remote sensing classification. *International Journal of Remote Sensing* 26: 217–222.
80. Murphy KP (2006). Naive bayes classifiers. *University of British Columbia* 18: 1–8.
81. Saritas MM, Yasar A (2019). Performance analysis of ANN and Naive Bayes classification algorithm for data classification. *International Journal of Intelligent Systems and Applications in Engineering* 7: 88–91.
82. Vapnik, VN (1995). *The nature of statistical learning theory*. Springer, New York, [online]. Available from: <http://dx.doi.org/10.1007/978-1-4757-2440-0>. [Accessed 10 Dec 2020].
83. Xuegong Z (2000). Introduction to statistical learning theory and support vector machines. *Acta Automatica Sinica* 26.1: 32-42.
84. Wang L (2005). *Support vector machines: theory and applications*. Springer Science & Business Media, Netherlands; Sayfa: 11-22.
85. Yegnanarayana B (2009). *Artificial neural networks*. Prentice Hall of India (PHI), Private Limited, Sayfa: 144:186.
86. Hassoun MH (1995). *Fundamentals of artificial neural networks*. Massachusetts Institute of Technology (MIT) Press, London; Sayfa: 57-87.
87. Priddy KL, Keller PE (2005). *Artificial neural networks: An introduction*. Society of Photographic Instrumentation Engineers (SPIE) Press, Washington; Sayfa: 35-46.
88. Pirim AGH (2006). Yapay zeka. *Journal of Yaşar University* 1: 81–93.
89. Bulut T (2019). Yapay zeka [online]. Available from: <https://tevfikbulut.com/2019/11/03/yapay-zeka/>. [Accessed 18 Dec 2020].
90. Koç ML, Balas CE, Arslan A (2004). Taş dolgu dalgakıranların yapay sinir ağları ile ön tasarımı. *Teknik Dergi*, 15: 3351-3375.
91. Çayıroğlu İ (2019). İleri Algoritma Analizi Ders Notları [online]. <http://www.ibrahimcayiroglu.com/Dokumanlar/IleriAlgoritmaAnalizi/IleriAlgoritmaAnalizi-5.Hafta-YapaySinirAglari.pdf>. [Accessed 23 Jan 2021].
92. Krenker A, Beşter J, Kos A (2011). Introduction to the artificial neural networks. *Artificial Neural Networks. Methodological Advances and Biomedical Applications InTech* 1–18.
93. Öztemel E (2003). *Yapay sinir ağları*. PapatyaYayincilik, İstanbul; 13-28.

94. Hatcher WG, Yu W (2018). A survey of deep learning: Platforms, applications and emerging research trends. The Institute of Electrical and Electronics Engineers 6: 24411–24432.
95. Buduma N, Locascio N (2017). Fundamentals of deep learning: Designing next-generation machine intelligence algorithms. O'Reilly Media, New York, Sayfa: 85-109.
96. Ivakhnenko AG, Lapa VG (1966). Cybernetic predicting devices. Purdue University, School of Electrical Engineering, New York, 66-5.
97. Fukushima K, Miyake S (1982). Neocognitron: A self-organizing neural network model for a mechanism of visual pattern recognition. Competition and Cooperation in Neural Nets Springer, 36. 4: 193-202.
98. LeCun Y, Boser B, Denker JS, Henderson D, Howard RE, Hubbard W, Jackel LD (1989). Backpropagation applied to handwritten zip code recognition. Neural Computation 1: 541–551.
99. LeCun Y, Boser B, Denker J, Henderson D, Howard R, Hubbard W, Jackel L (1989). Handwritten digit recognition with a back-propagation network. Advances in Neural Information Processing Systems, 27. 1: 41-46.
100. Hinton GE, Dayan P, Frey BJ, Neal RM (1995). The Wake-sleep algorithm for unsupervised neural networks. Science 268(5214): 1158-1161.
101. Hochreiter S, Schmidhuber J (1997). Long short-term memory. Neural Computation 9: 1735–1780.
102. Cortes C, Vapnik V (1995). Support-vector networks Machine learning. Kluwer Academic Publisher 20: 237-297.
103. Aizenberg IN, Aizenberg NN, Vandewalle J (2000). Multiple-Valued threshold logic and multi-valued neurons. Multi-Valued and Universal Binary Neurons Springer 25–80.
104. Hinton GE (2007). Learning multiple layers of representation. Trends in Cognitive Sciences 11: 428–434.
105. Deng L, Yu D (2014). Deep learning: methods and applications. Foundations and Trends in Signal Processing 7: 197–387.
106. Kim P (2017). Matlab deep learning. With machine learning, Neural Networks and Artificial Intelligence 130.
107. LeCun Y, Bengio Y, Hinton G (2015). Deep learning. Nature 521: 436–444.

108. Bengio Y (2009). Learning deep architectures for AI. *Foundations and Trends in Machine Learning* 2(1): 1-127.
109. Kaya U, Yılmaz A (2019). *Derin Öğrenme* 1-2. ISBN:978-605-2118-399.
110. LeCun Y, Bottou L, Bengio Y, Haffner P (1998). Gradient-based learning applied to document recognition. *Proceedings of The Institute of Electrical and Electronics Engineers (IEEE)* 86: 2278–2324.
111. Le Cun Y, Jackel LD, Boser B, Denker JS, Graf HP, Guyon I, Henderson D, Howard RE, Hubbard W (1989). Handwritten digit recognition: Applications of neural network chips and automatic learning. *The Institute of Electrical and Electronics Engineers (IEEE) Communications Magazine* 27: 41–46.
112. Ciresan DC, Meier U, Masci J, Gambardella LM, Schmidhuber J (2011). Flexible, high performance convolutional neural networks for image classification. *Twenty-second international joint conference on artificial intelligence*. [online]. Available from: <https://arxiv.org/pdf/1102.0183.pdf>. [Accessed 13 Jan 2021].
113. Farfade SS, Saberian MJ, Li L-J (2015). Multi-view face detection using deep convolutional neural networks. *Proceedings of the 5th ACM on International Conference on Multimedia Retrieval* 643–650.
114. Wallach I, Dzamba M, Heifets A (2015). AtomNet: A deep convolutional neural network for bioactivity prediction in structure-based drug discovery. [online]. Available from: <https://arxiv.org/pdf/1510.02855.pdf>. [Accessed 10 Dec 2020].
115. Yosinski J, Clune J, Nguyen A, Fuchs T, Lipson H (2015). Understanding neural networks through deep visualization. [online]. Available from: <https://arxiv.org/pdf/1506.06579.pdf>. [Accessed 2 Oct 2020].
116. Maddison CJ, Huang A, Sutskever I, Silver D (2014). Move evaluation in Go using deep convolutional neural networks. [online]. Available from: <https://arxiv.org/pdf/1412.6564.pdf>. [Accessed 28 Sep 2020].
117. Lee C-S, Wang M-H, Yen S-J, Wei T-H, Wu I-C, Chou P-C, Chou C-H, Wang M-W, Yan T-H (2016). Human vs. computer go: Review and prospect. *The Institute of Electrical and Electronics Engineers (IEEE) Computational Intelligence Magazine* 11: 67–72.
118. Zaremba W, Sutskever I, Vinyals O (2014). Recurrent neural network regularization. [online]. Available from: <https://arxiv.org/pdf/1409.2329.pdf>. [Accessed 24 Aug 2020].

119. Fischer A, Igel C (2012). An introduction to restricted Boltzmann machines. Iberoamerican Congress on Pattern Recognition Springer 14–36.
120. Mohamed A, Dahl GE, Hinton G (2011). Acoustic modeling using deep belief networks. The Institute of Electrical and Electronics Engineers (IEEE) transactions on audio, speech, and language processing 20: 14–22.
121. Krizhevsky A, Hinton GE (2011). Using very deep autoencoders for content-based image retrieval. European Symposium on Artificial Neural Networks (ESANN) 1.2: 489–494.
122. Field A (2009). Discovering statistics using spss. Sage Publications, London, 6-9.
123. Vaidya V (2021). Diabetes detection using convolutional neural network through feature sequencing. Turkish Journal of Computer and Mathematics Education (TURCOMAT) 12: 2783–2789.
124. Moitra D, Mandal RK (2020). Classification of non-small cell lung cancer using one-dimensional convolutional neural network. Expert Systems with Applications 159: 113564.
125. Hidaka A, Kurita T (2017). Consecutive dimensionality reduction by canonical correlation analysis for visualization of convolutional neural networks. Proceedings of the ISCIE international symposium on stochastic systems theory and its applications, The ISCIE Symposium on Stochastic Systems Theory and Its Applications 2017: 160–167.
126. Kalchbrenner N, Grefenstette E, Blunsom P (2014). A convolutional neural network for modelling sentences. [online]. Available from: <https://arxiv.org/pdf/1404.2188.pdf>. [Accessed 4 Nov 2020].
127. O'Shea K, Nash R (2015). An introduction to convolutional neural networks. [nline]. Available from: <https://arxiv.org/pdf/1511.08458.pdf>. [Accessed 11 Nov 2020].
128. Zamani Joharestani M, Cao C, Ni X, Bashir B, Talebiefandarani S (2019). PM2. 5 prediction based on random forest, XGBoost, and deep learning using multisource remote sensing data. Atmosphere Press 10: 373.
129. Jia H, Lin J, Liu J (2019). An earthquake fatalities assessment method based on feature importance with deep learning and random forest models. Sustainability Press 11(10): 2727.
130. Balki, I., Amirabadi, A., Levman, J., Martel, A. L., Emersic, Z., Meden, B., & Tyrrell, P. N. (2019). Sample-size determination methodologies for machine learning in

medical imaging research: a systematic review. Canadian Association of Radiologists Journal, 70(4), 344-353.





Ek 1. Etik Kurul Onay Belgesi



Ek 1. (Devam)



EK 1. (Devam)



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Soyadı, Adı : KALAYCI, Mehmet Erşan :

Uyruğu

Doğum Tarihi ve Yeri

E-Posta

Yazışma Adresi (İş)

EĞİTİM BİLGİLERİ

Derece	Mezun Olduğu Kurumun Adı	Mezuniyet
		Yılı
Yüksek Lisans	KTÜ Biyoistatistik ve Tıp Bilişimi	2021
Lisans	KTÜ İstatistik ve Bilgisayar Bilimleri Bölümü	2016
Lise	Vakıfkebir Anadolu Lisesi	2011

AKADEMİK/MESLEKİ DENEYİMİ

Görevi	Kurum	Süre
		(Yıl -Yıl)
1. Bursiyer	TÜBİTAK Projesi: 318S218	2020-2021

YABANCI DİL

İngilizce