

**T.C.
ERCIYES ÜNİVERSİTESİ
SAĞLIK BİLİMLERLERİ ENSTİTÜSÜ
BESLENME VE DİYETETİK ANABİLİM DALI**

**MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE
GELİŞTİRİLEN ERKEN UYARI SİSTEMİ İLE
ÇOCUKLUK ÇAĞI OBEZİTE RİSKİNİN SAPTANMASI**

**Hazırlayan
Burcu ÇAVDAR**

**Danışman
Prof. Dr. Betül ÇİÇEK**

Doktora Tezi

**Ağustos 2022
KAYSERİ**

**T.C.
ERCIYES ÜNİVERSİTESİ
SAĞLIK BİLİMLERLERİ ENSTİTÜSÜ
BESLENME VE DİYETETİK ANABİLİM DALI**

**MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE
GELİŞTİRİLEN ERKEN UYARI SİSTEMİ İLE
ÇOCUKLUK ÇAĞI OBEZİTE RİSKİNİN SAPTANMASI**

Doktora Tezi

Hazırlayan

Burcu ÇAVDAR

Danışman

Prof. Dr. Betül ÇİÇEK

**Ağustos 2022
KAYSERİ**

BİLİMSEL ETİĞE UYGUNLUK

Bu tezin kendi çalışmam olduğunu, tüm bilgilerin akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda akademik ve etik kuralların gerektirdiği gibi tüm materyal ve sonuçları tam olarak aktardığımı, başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel kurallara uygun olarak atıfta bulunduğumu ve kaynaklar listesinde gösterdiğimi belirtirim.

Adı-Soyadı: Burcu ÇAVDAR

İmza :

YÖNERGEYE UYGUNLUK ONAYI

“Makine Öğrenmesi Algoritmaları ile Geliştirilen Erken Uyarı Sistemi İle Çocukluk Çağı Obezite Riskinin Saptanması” adlı **Doktora Tezi**, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ne uygun olarak hazırlanmıştır.

Tezi Hazırlayan

Burcu ÇAVDAR

Danışman

Prof. Dr. Betül ÇİÇEK

Anabilim Dalı Başkanı

Prof. Dr. Betül ÇİÇEK

Prof. Dr. Betül ÇİÇEK danışmanlığında **Burcu ÇAVDAR** tarafından hazırlanan “**Makine Öğrenmesi Algoritmaları ile Geliştirilen Erken Uyarı Sistemi ile Çocukluk Çağı Obezite Riskinin Saptanması**” adlı bu çalışma jürimiz tarafından Erciyes Üniversitesi Sağlık Bilimleri Enstitüsü Beslenme ve Diyetetik Anabilim Dalında **Doktora** tezi olarak kabul edilmiştir.

29/08/2022

JÜRİ

Danışman: Prof. Dr. Betül ÇİÇEK

Üye : Prof. Dr. Neriman İNANÇ

Üye :Doç. Dr. Zeynep CAFEROĞLU

Üye : Dr. Öğr. Üyesi Biriz ÇAKIR

Üye : Dr. Öğr. Üyesi Serhat KILIÇARSLAN

ONAY

Bu tezin kabulü Enstitü Yönetim Kurulunun/...../2022 tarih ve sayılı kararı ile onaylanmıştır.

..... /...../ 2022

Prof. Dr. Bilal AKYÜZ

Enstitü Müdürü

TEŞEKKÜR

Doktora eğitimimde ve tez dönemimde benden bilgi, tecrübe, motivasyon ve yardımını asla esirgemeyen ve her an tüm desteğiyle yanımda olan değerli danışmanım Sayın Prof. Dr. Betül ÇİÇEK'e

Makine öğrenmesi yöntemi ile erken uyarı sisteminin geliştirilmesi sürecinde bana yol gösterici katkılar sağlayan Sayın Dr. Öğr. Üyesi Serhat KILIÇARSLAN'a,

Hayatım boyunca destekçim olan, ayrıca tez çalışmamın istatistiksel değerlendirmelerinde benden yardımını esirgemeyen abim Burak ÇAVDAR'a,

Hayatımın her anı ile beraber doktora eğitimim ve tez sürecim boyunca da her zaman sabırla ve sevgiyle yanımda olan hayatımı renklendiren tüm dostlarıma,

Beni her zaman sarıp sarmalayan, gücümü aldığım ve hayattaki en büyük destekçilerim olan canımdan çok sevdiğim aileme; Hatice ÇAVDAR, Ahmet ÇAVDAR, Hasan Baki ÇAVDAR ve Furkan Aras ÇAVDAR'a

Sonsuz Teşekkürler...

Burcu ÇAVDAR

Kayseri, Ağustos, 2022

MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE GELİŞTİRİLEN ERKEN UYARI SİSTEMİ İLE ÇOCUKLUK ÇAĞI OBEZİTE RİSKİNİN SAPTANMASI

Burcu ÇAVDAR

Erciyes Üniversitesi Sağlık Bilimleri Enstitüsü

Beslenme ve Diyetetik Anabilim Dalı

Doktora Tezi, Ağustos 2022

Danışman: Prof. Dr. Betül ÇİÇEK

ÖZET

Günümüzde çocukluk çağı obezite riskini tahmin edebilecek bilgisayar programları kullanılmaktadır. Çalışmanın amacı, makine öğrenmesi yaklaşımlarıyla çocukluk çağı obezite riskini tahmin edebilen erken uyarı sistemi geliştirmek ve bu sayede çocuklarda obezite henüz gelişmeden tespit edilebilmesine katkı sağlamaktır. İlk aşamada çocukluk çağı obezite riskini tahmin edebilen dinamik bir erken uyarı sistemi kurulmuştur. Sistem için Navie Bayes, k-en yakın komşu, yapay sinir ağı, karar ağacı, lojistik regresyon ve destek vektör makinesi algoritmalarının performansları doğruluk, duyarlılık, hassasiyet, F-ölçütü, Matthews korelasyon katsayısı, Kappa istatistiği değerleri ile belirlenmiştir. En yüksek doğrulukta tahmin işlemini karar ağacı algoritması gerçekleştirdiği için sistem bu algoritmayla kurulmuş ve bulut sağlayıcısına aktarılarak web tabanlı dinamik bir sisteme dönüştürülmüştür. İkinci aşamada sistem tarafından 100 çocuğun obezite risk tahminleri yapılmıştır. Sistem sonuçları ile obezite risk faktörleri arasındaki ilişki incelenerek sistemin doğruluğu teyit edilmiştir. Sonuç olarak çocukluk çağı obezite riski için %94 başarıyla tahmin işlemi gerçekleştiren bir erken uyarı sistemi kurulabilmiş ve çağımızın en ciddi problemlerinden olan obezite için gerekli önlemlerin henüz ortaya çıkmadan alınabilmesi mümkün hale gelmiştir.

Anahtar Sözcükler: Karar Ağacı; Makine Öğrenmesi; Obezite; Sınıflandırma; Yapay Zekâ.

DETECTION THE RISK OF CHILDHOOD OBESITY BY EARLY WARNING SYSTEM DEVELOPED WITH MACHINE LEARNING ALGORITHMS

Burcu ÇAVDAR

Erciyes University, Graduate School of Health Sciences

Department of Nutrition and Dietetics

Ph.D. Thesis, August 2022

Supervisor: Prof. Dr. Betül ÇİÇEK

ABSTRACT

Complex computer programs are used to predict the risk of childhood obesity. The aim of the study is to develop an early warning system that can predict the risk of childhood obesity with a machine learning approach and to contribute to the detection of obesity in children before it develops. In the first stage of the study, a dynamic early warning system that can predict childhood obesity risk. Naive bayes, k-nearest neighbor, artificial neural network, decision tree, logistic regression and support vector machine algorithms are used for the early warning system. The performances of the models were determined by accuracy, recall, sensitivity, F-measure, Matthews correlation coefficient and Kappa statistic. The decision tree algorithm performed the prediction with the highest accuracy. The system was established with the decision tree algorithm. The system was transferred to the cloud provider and transformed into a web based dynamic system. In the second stage of the study, the obesity risks of 100 children were calculated. The accuracy of the system was confirmed by examining the relationship between system results and obesity risk factors. As a result, an early warning system that can predict childhood obesity risk with a success rate of 94% has been established. In this way, it has become possible to take the necessary measures for obesity, which is one of the most serious problems of our century, before it occurs.

Keywords: Artificial Intelligence Classification; Decision Tree; Machine Learning; Obesity.

İÇİNDEKİLER

Sayfa No

İÇ KAPAK	
BİLİMSEL ETİĞE UYGUNLUK	i
YÖNERGEYE UYGUNLUK ONAYI.....	ii
KABUL VE ONAY SAYFASI	iii
TEŞEKKÜR.....	iv
ÖZET.....	v
ABSTRACT.....	vi
İÇİNDEKİLER	vii
KISALTMALAR	ix
TABLO LİSTESİ.....	x
ŞEKİL LİSTESİ.....	xii
1. GİRİŞ VE AMAÇ	1
2. GENEL BİLGİLER.....	3
2.1. Çocukluk Çağı Obezitesi.....	3
2.1.1. Tanımı ve sıklığı.....	3
2.1.2. Çocukluk Çağı Obezitesi Risk Faktörleri.....	4
2.1.3. Çocukluk Çağı Obezitesinin Komorbiditeleri.....	9
2.1.4. Çocukluk Çağı Obezitesinin Değerlendirilmesi.....	10
2.1.5. Çocukluk Çağı Obezitesinin Tedavisi.....	11
2.1.6. Çocukluk Çağı Obezitesinin Önlenmesi	12
2.2. Yapay Zekâ	14
2.2.1. Sağlık Alanında Yapay Zekâ Uygulamaları.....	14
2.2.2 Beslenme ve Diyetetik Alanında Yapay Zekâ Uygulamaları	15
2.3. Makine Öğrenmesi	17
2.3.1. Makine Öğrenmesi Uygulama Süreci	18
2.3.2. Makine Öğrenmesinde Öğrenme Yöntemleri	21

2.3.3. Makine Öğrenmesinde Sınıflandırma Algoritmaları.....	23
2.3.4. Makine Öğrenmesinde Modellerin Başarı Ölçütleri	29
2.4. Sistemin Geliştirilmesinde Kullanılan Programlar	32
2.4.1. Waikato Bilgi Analizi Ortamı	32
2.4.2. Python.....	32
2.4.3. Visual Studio Code.....	33
2.4.4. Heroku.....	33
2.4.5. GitHub.....	33
3. GEREÇ VE YÖNTEMLER.....	34
3.1. Makine Öğrenmesi Süreci.....	36
3.1.1. Problemin Tanımlanması	37
3.1.2. Veriyi Anlama.....	37
3.1.3. Veri Hazırlama	41
3.1.4. Modelleme;.....	43
3.1.5. Model Değerlendirme ve Seçimi;	44
3.1.6. Modelin Uygulamaya Geçirilmesi;	45
3.2. Geliştirilen Sistemi Uygulama Süreci	54
3.3. İstatistiksel Analiz	55
4. BULGULAR	56
4.1. Veri Setine Ait Bulgular.....	56
4.2. WEKA Uygulamasına Ait Bulgular.....	62
4.2.1. WEKA Ön İşlem (Preprocess) Sekmesi Sonuçları	63
4.2.2. Makine Öğrenmesi Algoritmaları ile Kurulan Modellere ait Bulgular... ..	64
4.2.3. Geliştirilen Modellerin Performans Ölçütlerinin Karşılaştırılması.....	70
4.3. J 48 Modeli ile Kurulan Sisteme ait Bulgular	71
4.3.1.Sistemim Tahmin Sonuçları ile Öznitelikler Arasındaki İlişki	71
5. TARTIŞMA VE SONUÇ.....	78
7.KAYNAKLAR	96
EKLER	
ÖZGEÇMİŞ	

KISALTMALAR

BKİ	: Beden Kütle İndeksi
CRISP-DM	: Cross Industry Standart Processfor Data Mining
DSÖ	: Dünya Sağlık Örgütü
DVM	: Destek Vektör Makinesi
FN:	: False Negative
FP:	: False Positive
KVH	: Kardiyovasküler hastalıklar
Kg:	: Kilogram
kNN	: k-Nearest Neighbors
MAE	: Mean Absolute Error
MCC	: Matthews Correlation Coefficient
NB	: Naive Bayes
NAYKH	: Nonalkolik Yağlı Karaciğer Hastalığı
PKOS	: Polikistik Over Sendromu
PHP	: Hypertext Preprocessor
RMSE	: Root Mean Squared Error
TBSA	: Türkiye Beslenme ve Sağlık Araştırması
TN	: True Negative
TP	: True Positive
TÜBER	: Türkiye Beslenme Rehberi
UNICEF	: United Nations ChildrenFund
WHO	: World Health Organization
YSA	: Yapay Sinir Ağları

TABLO LİSTESİ

Sayfa No

Tablo 2.1.	Çocuklarda ve Ergenlerde Persentil Değerlerine göre BKİ Sınıflandırması	11
Tablo 2.2.	Karmaşıklık Matrisi Modeli	30
Tablo 3.1.	Veri Setinin İçerdiği Öznitelikler ve Özniteliklere Atanan Değerler .	39
Tablo 3.2.	Sınıflara Atanan Değerler ve Verilerin Sınıflara Göre Dağılımı.....	41
Tablo 4.1.	Gruplara Göre Demografik Özelliklerin Dağılımı	57
Tablo 4.2.	Antropometrik Ölçüm Değerlerinin Ortalamaları	57
Tablo 4.3.	Gruplara Göre Yaşamın İlk 1000 Gününe Ait Özelliklerin Dağılımı	58
Tablo 4.4.	Gruplar Arasında Öğün Tüketim Sıklığının Dağılımı.....	59
Tablo 4.5.	Bazı Besinlerin Tüketim Sıklığının Gruplar Arasındaki Dağılımı.....	60
Tablo 4.6.	Gruplara Göre Psikolojik ve Genetik Faktörlerin Dağılımı	61
Tablo 4.7.	Gruplara Göre Gün İçerisindeki Aktivite ve Ekran Sürelerinin Dağılımı.....	62
Tablo 4.8.	Naive Bayes Algoritması Karmaşıklık Matrisi	64
Tablo 4.9.	IBk (k-en yakın komşu) Algoritması Karmaşıklık Matrisi	65
Tablo 4.10.	Yapay Sinir Ağı Algoritması Karmaşıklık Matrisi	66
Tablo 4.11.	J48 (Karar Ağacı) Algoritması Karmaşıklık Matrisi.....	67
Tablo 4.12.	Lojistik Regresyon Algoritması Karmaşıklık Matrisi	68
Tablo 4.13.	Destek Vektör Makinesi (LibSVM) Algoritması Karmaşıklık Matrisi.....	69
Tablo 4.14.	Makine Öğrenmesi Algoritmalarının Sınıflandırma Performans Ölçütleri.....	70
Tablo 4.15.	Demografik Özellikler in Sistem Tahmin Sonuçlarına Göre Dağılımı.....	72
Tablo 4.16.	Sistem Tahmin Sonuçlarına Göre Antropometrik Ölçümlerin Ortalaması.....	73
Tablo 4.17.	Sistem Tahmin Sonuçlarına göre BKİ Gruplarının Dağılımı.....	74
Tablo 4.18.	Sistem Tahmin Sonuçlarına Göre Yaşamın İlk 1000 Gününe ait Özelliklerin Dağılımı.....	74

Tablo 4.19.	Sistem Tahmin Sonuçlarına Göre Öğün Tüketim Sıklıklarının Dağılımı	75
Tablo 4.20.	Sistem Tahmin Sonuçlarına Göre Çeşitli Besinlerin Tüketim Sıklıklarının Dağılımı	76
Tablo 4.21.	Sistem Tahmin Sonuçlarına göre Psikolojik ve Genetik Faktörlerin Dağılımı	76
Tablo 4.22.	Sistem Çıktı Sonuçlarına göre Gün İçerisindeki Aktivite ve Ekran Sürelerinin Dağılımı	77



ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1.	Yapay Zekâ, Makine Öğrenmesi	18
Şekil 2.2.	CRISP-DM Modeli.....	19
Şekil 2.3.	Lojistik Regresyon Basitleştirilmiş Çizimi	23
Şekil 2.4.	Navie Bayes Basitleştirilmiş Çizimi.....	24
Şekil 2.5.	K-En Yakın Komşu Algoritmasının Basitleştirilmiş Çizimi	25
Şekil 2.6.	Destek Vektör Makinesinin Basitleştirilmiş Çizimi	26
Şekil 2.7.	Yapay Sinir Ağının Basitleştirilmiş Çizimi.....	27
Şekil 2.8.	Karar Ağacı Modellemesi.....	29
Şekil 3.1.	Çalışmanın Akış Diyagramı	35
Şekil 3.2.	Makine Öğrenmesi Süreci Gerçekleştirilirken Uygulanan Adımlar ..	36
Şekil 3.3.	WEKA 3.8.5 Giriş Ekranı	42
Şekil 3.4.	WEKA programında normalizasyon işlemi	43
Şekil 3.5.	Karar Ağacı Algoritması ile Kurulan Modelin Kodları	48
Şekil 3.6.	Sistemin Web Alt Yapısının (@app) Kodları.....	50
Şekil 3.7.	İndex.html Dosyasından Bir Kesit	51
Şekil 3.8.	Heroku Kodları.....	52
Şekil 3.9.	Web Sayfası Görünümü 1/2	53
Şekil 3.10.	Web Sayfası Görünümü 2/2	53
Şekil 3.11.	Web Uygulaması Kullanıcı Ara Yüzü Sonuç Ekranı 1	54
Şekil 3.12.	Web Uygulaması Kullanıcı Ara Yüzü Sonuç Ekranı 2	54
Şekil 4.1.	Veri Setinin Özniteliklerinin Gruplara Göre Dağılımı 1	63
Şekil 4.2.	Veri Setinin Özniteliklerinin Gruplara Göre Dağılımı 2	63
Şekil 4.3.	Naive Bayes Modeli Performans Ölçüt Sonuçları.....	64
Şekil 4.4.	IBk (k-en yakın komşu) Modeli Performans Ölçüt Sonuçları.....	65
Şekil 4.5.	Multilayer Perception (YSA) Modeli Performans Ölçüt Sonuçları ..	66
Şekil 4.6.	J48 (Karar Ağacı) Modeli Performans Ölçüt Sonuçları	67
Şekil 4.7.	Logistic (Lojistik Regresyon) Modeli Performans Ölçüt Sonuçları...	68
Şekil 4.8.	Destek Vektör Makinesi (LibSVM) Modeli Performans Ölçüt Sonuçları.....	69

Şekil 4.9.	Gruplara Göre Cinsiyet Dağılımı	71
Şekil 4.10.	Gruplara Göre Yaş Dağılımı	72
Şekil 4.11.	Gruplara Göre Antropometrik Ölçüm Değerlerinin Dağılımı.....	73



1. GİRİŞ VE AMAÇ

Obezitenin sıklığı, ırk, yaş ve cinsiyete göre değişmektedir ve tüm dünyada hızla artan bir eğilim göstermektedir. Obezite genel olarak bir yetişkin hastalığı gibi algılanmaktadır, ancak özellikle az gelişmiş ve gelişmekte olan ülkelerde çocuklarda obezite prevalansının çok hızlı artması, çocukluk çağı obezitesinin küresel boyutta bir halk sağlığı problemi yaratacağının ciddi bir göstergesidir. Son yıllarda dünya genelinde çocuk ve ergenlerde obezite oranları ciddi bir şekilde artış göstermektedir. Yetişkinlik döneminde ortaya çıkabilecek obezite ve kronik hastalıkların önlenmesi açısından çocukluk çağı obezitesinin önlenmesi çok önemlidir (HSGM, 2019; WHO, 2018).

Çocukluk döneminde obezite, özellikle 4–6 yaş arasında ve gelişim döneminde hızlı artış göstermektedir (HSGM 2019). Yetişkinlik döneminde görülen obezitenin büyük bir kısmının çocukluk dönemi obezitesi ile ilişkili olduğu bilinmektedir (TÜBER, 2015). Bu nedenle çocukluk döneminde obezitenin erken teşhisinin sağlanması obeziteden korunma ve obezitenin tedavisi için oldukça önemlidir. Gerekli tedbirler çocukluk döneminde alınmadığı takdirde, obezitenin ileri yaşlardaki tedavisi daha da zorlaşmaktadır (Günöz, 2010).

Çocukluk çağında obezitenin henüz ortaya çıkmadan tespit edilebilmesi, okullarda yapılan sağlık taramalarıyla ya da ailelerin beslenme problemi olan çocukları için sağlık kuruluşlarına başvurmaları ile yapılabilmektedir. Bununla birlikte günümüzde her alanda olduğu gibi yapay zekâ, makine öğrenmesi, derin öğrenme gibi son teknolojilerden sağlık alanında da etkin bir şekilde faydalanılmaktadır. Yapay zekâ, herhangi bir konuda tahmin işlemi veya karar verme işlemini gerçekleştiren teknolojilere verilen genel tanımdır. Makine öğrenmesi ise tamamen veriyi kullanarak veriden öğrenmektedir (Chollet, 2017; Hal Daumé III, 2012).

Makine öğrenmesi algoritmaları ile uzmanların kararına destek olabilecek veya uzman yokluğunda karar verebilecek, çeşitli hastalıkların teşhisi veya hastalık risklerinin tahmin işlemini gerçekleştirebilecek sistemlere dair birçok çalışma yapılmaktadır (Anselma ve ark., 2017; Topol, 2019; Garcia ve ark., 2021). Makine öğrenmesi yaklaşımı ile doğru veri doğru tekniklerle işlenirse doğru kararlar alabilecek otomatik bir sistem oluşturulabilir (Chollet, 2017). Makine öğrenmesi yaklaşımında denetimli öğrenme yöntemlerinden sınıflandırma algoritmaları da bu alanda kullanılmaktadır. Sınıflandırma algoritmaları hastalıklar ile ilgili geçmişe yönelik verileri kullanarak kendisini eğitir. Eğitimi tamamlanan algoritma daha sonra olası hastalar veya hastalıklar için tahmin işlemi gerçekleştirebilmektedir. (Özata M. ve Aslan Ş, 2004; Komesli, 2007; Tian-en ve ark., 2009).

Günümüzde birçok hastalık riskini tahmin edebilecek, akıl yürüterek karar verme özelliğine sahip karmaşık bilgisayar programları kullanılmaktadır (Tian-en ve ark., 2009). Alanda uzman bilgisayar mühendisi ve diyetisyenin birlikte hazırlayacağı veri setleri ile makine öğrenmesi algoritmaları kullanılarak yapay ve özgün bir sistem geliştirildiğinde, çocukluk çağı obezitesi teşhisi yapabileceği gibi gelecek dönemler için obezite risk düzeyleri de saptanabilir.

Obezite ile mücadelede erken uyarı sistemi geliştirilmesi ile ilgili çalışmalar mevcuttur (Abdullah ve ark., 2017; Adnan ve ark., 2012; Bulut ve ark., 2017; Ergün, 2009; Hammond ve ark., 2019; Heydari ve ark., 2017; Kim ve ark., 2019; Wiechman ve ark., 2017; Zhang ve ark 2009). Ancak, bunlar daha çok hangi makine öğrenmesi algoritmasının daha başarılı sonuç verdiğini araştırmaya yönelik veya algoritmaların başarı metriklerinin karşılaştırıldığı mühendislik çalışmalarıdır. Ancak literatürde Beslenme ve Diyetetik alanında yapılmış makine öğrenmesi ile çocukluk çağı obezitesi için web tabanlı bir erken uyarı sistemi geliştirilmesine dair herhangi bir çalışmaya rastlanmamıştır. Bu çalışmanın Beslenme ve Diyetetik alanında yapay zekâ ve makine öğrenmesi ile ilgili yapılacak yeni çalışmalara da ışık tutacağı düşünülmektedir. Bu çalışmanın amacı; çağımızın hızla artan problemi olan obezitenin henüz ortaya çıkmadan tespit edilmesini sağlayacak, kolay ulaşılabilirliği ve basit kullanımı ile herkesin kullanabileceği web tabanlı bir sistem geliştirip, çocukların obezite risklerini saptayarak, obezite henüz gelişmeden gerekli önlemlerin alınmasına katkı sağlamaktır.

2. GENEL BİLGİLER

2.1. Çocukluk Çağı Obezitesi

2.1.1. Tanımı ve sıklığı

Dünya Sağlık Örgütü (DSÖ), obeziteyi “Sağlığı bozacak ölçüde anormal veya aşırı yağ birikmesi” olarak tanımlamaktadır. Günümüzde obezite çocukluk çağının en sık görülen kronik sağlık sorunlarından birisidir. Ayrıca çocukluk çağındaki obezitenin erişkin yaşlardaki aşırı vücut ağırlığı/obezite ile ilişkili olduğu bilinmektedir. Erişkin dönemde ortaya çıkabilecek metabolik hastalıklar, kas-iskelet sistemi hastalıkları, kardiyovasküler hastalıklar ve kanser gibi bulaşıcı olmayan kronik hastalıkların önlenmesi için çocukluk çağı obezitesinin önlenmesi büyük önem taşımaktadır (WHO, 2014).

Son yıllarda gelişmiş ve gelişmekte olan ülkelerde okul öncesi dönemde obezite prevalansı hızlı bir oranda artış göstermektedir (Benton ve ark., 2015; de Onis ve ark., 2010; Greydanus ve ark., 2018). United Nations Children Fund (UNICEF), DSÖ ve Dünya Bankası’nın 2018 yılında yayınladığı rapora göre, dünya genelinde 5 yaş altı hafif şişman çocuk sayısının 38,3 milyon (%5.6) olduğu bildirilmiştir. Raporda 2000-2013 yılları arasında obez çocuk sayısının 32 milyondan 42 milyona yükseldiği ve bu sayının 2025 yılında 70 milyona ulaşacağı tahmin edilmektedir (WHO, 2014; WHO, 2018). Dünya genelinde düşük ve orta gelirli ülkelerde 5 yaş altında hafif şişman ve obez çocukların oranı zayıf çocukların oranından daha fazladır (Gurnani ve ark., 2015). Avrupa’ya bakıldığında da düşük gelir gruplarında obezite görülme sıklığının anlamlı olarak daha yüksek olduğu görülmektedir (Manios ve ark., 2018). Ülkemizde 0-5 yaş arası çocuklarda hafif şişman (%8.5) ve obez (%17.9) çocukların toplam oranının %26.4 olduğu saptanmıştır.

Obezitenin 0-5 yaş grubunda en sık görüldüğü bölgelere bakıldığında sırasıyla en yüksek Doğu Karadeniz, Batı Karadeniz ve Orta Anadolu olduğu görülmüştür (TBSA, 2019).

Obezite, ülkelerin ekonomilerini doğrudan veya dolaylı olarak etkilemektedir. Gelişmiş ülkelerde obezite ile ilgili sağlık harcamaları toplam sağlık harcamalarının %2-7'sini oluşturmaktadır (HSGM, 2019). Koruyucu sağlık önlemleri ile bazı ülkelerde obezite artış hızının durdurulmasının sağlandığı bildirilmektedir (Çatlı ve Büyükgebiz, 2015). Okul öncesi dönemde başlayan obezite ilerleyen dönemlerde derecesi artarak devam etmektedir. Yetişkinlik döneminde obez olan kişilerin yaklaşık %33'ünün çocukluk döneminde de hafif şişman-obez olduğu saptanmıştır (TÜBER, 2015). Hafif şişman çocukların yaklaşık %55'inin adolesan dönemde obez olduğu ve %80'inin yetişkinlik döneminde de obezite ile mücadele ettiği bildirilmektedir (Simmonds ve ark., 2016). Bu sebeple okul öncesi dönemde çocukların obeziteye yakalanma risklerinin azaltılmasına yönelik olarak yapılan çalışmalarla obezite prevalansının azaltılmasında okul öncesi çağı çocuklar en önemli hedef grup olduğu bilinmektedir (Towner ve ark., 2016; Wang, 2017).

2.1.2. Çocukluk Çağı Obezitesi Risk Faktörleri

Çocukluk çağı obezitesine neden olduğu bilinen birçok faktör vardır. Bunlardan en önemlilerinin ise yetersiz, dengesiz ve aşırı beslenme ile fiziksel aktivite yetersizliğidir. Ayrıca obezite genetik ve çevre koşulları, fizyolojik, psikolojik pek çok faktörlerden de etkilenen kompleks bir problemdir (Gurnani ve ark., 2015). Enerji alımı ile enerji harcaması arasındaki dengesizlik, öğün tüketim sıklığı, yüksek miktarda şeker içeren yiyeceklerin ve içeceklerin fazla miktarda tüketilmesi, gün içerisinde televizyon, bilgisayar, internet ve cep telefonu başında geçirilen sürenin fazla olması, fiziksel inaktivite, bazı beslenme ve yaşam tarzı faktörleri, düşük ya da fazla doğum ağırlığı, annenin gebelikte fazla ağırlık kazanımı, mama formüla tüketimi, çocukluk dönemi travmaları, obez ebeveyn vb. sebepler çocukluk çağı obezite riskini artırmaktadır (HSGM, 2019). Obezogenik çevre; hızlı ağırlık kazanımını kolaylaştıran çevre olarak tanımlanabilir (Gauthier ve Krajicek, 2013; Karaçil ve Şanlıer, 2014). Obezogenik çevre koşulları değiştirilerek çocukluk çağı obezite riskinin azaltılabileceği belirtilmektedir (Pirgon, 2015).

Okul öncesi çağı çocuklarda obezite ile ilişkili en önemli çevresel faktör ise ailedir. Ailenin yemek düzeni, yeme alışkanlıkları çocuğun beslenme alışkanlığının temel belirleyicisidir. Çocuğun beslenme alışkanlığının oluşmasında anne başta olmak üzere aile bireyleri çok önemlidir. Annenin ve babanın eğitim düzeyi ve mesleği çocuğun beslenme alışkanlığı ile ilişkili ana faktörlerdendir (Yabancı ve ark., 2014).

Ebeveynlerin beden kütle indeksi (BKİ) değerlerinin yüksek olmasının çocuklarının BKİ değerlerinin yüksek olmasıyla ilişkili olduğu bilinmektedir (Wang, 2017). Çocuğun obez olma riskinin anne ve babanın her ikisi de obez ise %80, anne veya babadan sadece biri obez ise %40, her ikisi de normal ağırlıkta ise %14 olduğu bildirilmiştir (Işgın ve Demirel, 2017). Bir çalışmada annenin BKİ değerinin $>30 \text{ kg/m}^2$ olmasının, çocuğun hafif şişman veya obez olma riskini artırdığı gösterilmiştir (Vehapoglu ve ark., 2017). Ebeveynlerinden biri obez olan okul öncesi çağı çocukların, ebeveynleri normal ağırlıkta olan çocuklara göre obezite riski 1.9 kat daha fazladır. Ebeveynleri obez olan çocukların, ebeveynleri normal ağırlıkta olanlara göre daha fazla sedanter aktivitelere eğilimli olduğu bildirilmiştir. Ebeveynlerinden en az biri obez olan çocukların daha çok paketli yiyecek ve yüksek yağ içeren besin tükettiği ve daha az sebze tükettiği, ayrıca bu çocuklarda ağırlık kazanımı ile sonuçlanan hatalı beslenme alışkanlıklarının daha fazla gözlemlendiği bildirilmiştir (Dev ve ark., 2013). Ayrıca, 4 yaş grubunda aile ile beraber akşam yemeği tüketimi ve ekran süresini kısıtlama gibi bazı alışkanlıkları değiştiren çocuklarda bu alışkanlıkları değiştirmeyen çocuklara göre daha az oranda obezite görüldüğü bildirilmiştir (Anderson ve Whitaker, 2010).

Gelişmiş ülkelerde düşük sosyo-ekonomik düzeyde obezite görülme riski, yüksek sosyoekonomik düzeydekilere göre daha yüksektir. Gelişmekte olan ülkelerde ise yüksek sosyoekonomik düzeydeki kişilerin obez olma riski daha yüksektir (Salehiniya ve ark., 2016). Gelişmiş ülkelere göre düşük sosyoekonomik düzeydekilerin obez olma oranlarının daha yüksek olmasının nedeni çoğunlukla, sağlıklı besinleri daha az tercih etmesi ve bu grubun fiziksel aktivite imkânlarının daha az olmasıdır. Ayrıca eğitim seviyesi düşük ailelerin çocuklarının obez olma riski yüksektir ve bu sorun düşük sosyo-ekonomik düzeydeki kişileri daha fazla etkilemektedir (Avrupa Gıda ve Beslenme Eylem Planı 2015-2020, 2014).

Avrupa’da 3-5 yaş grubu çocuklar üzerinde yapılan bir çalışmada, çocuğun ailesinde obezite öyküsünün olması ve sosyo-ekonomik düzeyin düşük olmasının yüksek obezite oranı ile ilişkili olduğu görülmüştür (Manios ve ark., 2019).

Okul öncesi çağı, çocuklarda beslenme alışkanlıklarının temelini atıldığı en önemli dönemdir (TÜBER, 2015). Öğün atlama durumu, enerji alımını artırarak obezite oluşumuna zemin hazırlayan hatalı bir beslenme alışkanlığıdır (Karaçil ve Şanlıer, 2014). Okul öncesi dönemde öğün sayısının fazla olması, azalmış obezite riski ile ilişkilidir (Kaisari ve ark 2013). Almanya’da 5-6 yaş grubu çocuklarla yapılan bir çalışmada öğün sayısı günde 3’ten az olan çocuklarda obezite sıklığı %4.2 iken 5 öğünden fazla olanlarda ise %1.7 bulunmuştur (Toschke ve ark., 2005). Okul öncesi ve okul çağı çocuklarında kahvaltı günün en çok atlanan öğünüdür. Kahvaltının atlanması çocukların günün geri kalan öğünlerinde daha fazla besin tüketmelerine neden olmaktadır (Alsharairi ve Somerset, 2016). Kahvaltı öğününü atlayan çocuklarda obezite daha sık görülmektedir (TÜBER, 2015). Yapılan bir çalışmada 4 yaşında kahvaltı öğününü atlayan çocukların, 6 yaşında vücut yağ oranlarının daha fazla olduğu görülmüştür (Wijtzes ve ark., 2016).

Paketli yüksek şeker ve yağ içeren yiyecek ve içeceklerin ve fastfood ürünlerin enerji içeriği çok yüksektir. Yüksek miktarda yağ, şeker ve tuz içeren, posa içeriği düşük olan ve kan glikozunu hızla yükselten bu tür yiyeceklerin tüketilmesi, obeziteye yol açan en önemli etkenlerdendir. Amerika Birleşik Devletleri’nde, son 20 yıl içinde, 2-5 yaş arasındaki çocukların günlük enerji alımları paketli yüksek şeker ve yağ içeren yiyecek ve içeceklerin katkısı ile %30 oranında artmıştır. Bu tür yiyeceklerin tüketimindeki artış ile çocuklarda ve ergenlerde obezite, diş çürüğü ve diğer kronik hastalıklardaki artış arasında bir ilişki olduğu bildirilmiştir (Jackson ve ark., 2004).

Yüksek miktarda şeker içeren içeceklerin tüketimi okul öncesi çağı çocuklarında yaygındır (Shashaj ve ark., 2016). Yapılan çalışmalarda çocukluk çağında şeker içeriği yüksek içeceklerin tüketimi yüksek vücut yağ oranı ve obezite ile ilişkilendirilmektedir (Jacquier ve ark., 2018).

Çocukların mental, motor ve sosyal becerilerin ve kas-iskelet sisteminin gelişmesi için yeterli fiziksel aktivite önemlidir (DSÖ, 2016). Fiziksel aktivite veya çocukların

oyun oynayabilmeleri için gereken fiziksel imkânların karşılanamaması hareketsiz geçirilen süreyi artırarak, ağırlık kazanımına ortam hazırlamaktadır (Pirgon, 2015). Televizyon, tablet, telefon ve bilgisayar gibi ekran başında geçirilen sürenin artması da çocukların fiziksel aktiviteye daha az zaman ayırmasına neden olmaktadır (Caferoğlu, 2017). Okul öncesi çağı çocukların uyanık oldukları sürenin %52-70'ini sedanter olarak (masa başında ve oturarak yapılan oyunlar/aktiviteler) ile geçirdikleri bildirilmiştir (Towner, 2016). Amerikan Pediatri Akademisi'ne göre çocukluk döneminde ekran başında geçirilen sürenin artması ile çocuklarda sedanterlik artmakta ve fiziksel uğraşlar ile geçirilen süre azalmaktadır. Televizyon başında geçirilen sürede reklamlar sebebiyle de çocukların sağlıksız yiyecek tüketimi artmakta ve ekran karşısında atıştırma alışkanlığı oluşabilmektedir. Tüm bu sebepler okul öncesi çağı çocuklarda obezite oluşumuna katkı sağlamaktadır (Council on Communications and Media-2011). Beş yaşındaki çocuklarda TV izleme süresinin her bir saat artışı yetişkinlikteki obezite riskini %7 oranında artırdığı bildirilmiştir (Viner ve Cole, 2005). İki yaş üstü çocuklar için ekran süresinin günlük en fazla 2 saat olması önerilmektedir (Council on Communications and Media-2011).

Çocuğun stresli bir duruma veya ortama maruz kalması veya travmatik bir olay yaşaması, çocukluk çağı obezitesi için bir diğer risk faktörüdür (Brown ve ark., 2015). Ebeveynlerin çocuğa yetersiz zaman ayırması, çocuğun ekran karşısında geçirdiği süreyi artırarak hareketsiz bir yaşam sürmesine ve daha fazla besin tüketmesine neden olabilmektedir (Pirgon, 2015). Annede depresyon varlığı, aile bağlarının zayıf olması, anne babanın boşanmış olması, aile içi sorunlar ve ailede geçirilmiş travmatik olay öyküsü çocukluk çağı obezitesi için risk faktörleridir (Suglia ve ark., 2012).

Çocuğun anne karnındaki ilk gününden itibaren yaşamının ilk 1000 gününün, çocukluk çağı obezitesinin gelişmesinde en kritik dönem olduğu bilinmektedir (Woo ve ark., 2016). Çalışmalar, optimal olmayan intrauterin çevrenin, fetüsün gelişim aşamalarını etkileyerek gelecekte kronik hastalıkların oluşumunu etkileyebileceğini göstermektedir (Mutlu, 2015). Yapılan çalışmalarda fetal büyüme, doğum ağırlığı, doğum haftası, gebelikte aşırı ağırlık kazanımı gibi bazı faktörlerin çocukluk çağı obezitesi açısından risk oluşturabileceği görülmektedir (Woo ve ark., 2016).

Anne st saėlıklı byme ve geliřme iin gereken tm enerji ve besin gelerini ierisinde barındıran en ideal ve ocuėa zel ieriėe sahip doėal bir besindir. Dnya Saėlık rgt ve UNICEF, ilk 6 ay sadece anne st verilmesini ve en az 2 yıl anne stne devam edilmesini nermektedir. Bu sayede kısa ve uzun dnemde obezite ve kronik hastalık riskinin azaltılabileceėi bildirilmektedir (HSGM, 2019; Yan ve ark., 2014). Dnya Saėlık rgt, 2025 yılına kadar sadece anne st kullanımını en az %50'ye ıkarmayı hedeflemektedir (WHO, 2018). Anne stnn formula besinlere gre birok stnlė vardır (Mameli ve ark., 2016). Yapılan alıřmalarda sadece anne st ile beslenme sresinin 6 aydan kısa olmasının ocukluk aėı obezitesi ile pozitif iliřkili olduėu bildirilmiřtir (Robinson ve ark., 2015). Anne st ve ocukluk aėı obezitesinin iliřkisini inceleyen bir meta-analizde anne st ile beslenmenin ocukluk aėı obezitesi riskini anlamlı olarak azalttıėı bildirilmiřtir (Yan ve ark., 2014). Anne st; leptin, inslin, adiponektin ve obestatin gibi enerji metabolizmasını ve besin alımını dzenleyen hormonları iermesi sebebiyle de obeziteye karřı doėal koruyuculuėu olan zel bir besindir. Ayrıca anne st ieriėindeki sindirilemeyen oligosakkaritler prebiyotik etkisi sayesinde bebeėin mikrobiyotasını dzenleyerek obezite oluřumunu nlemektedir (García ve ark., 2018).

Altıncı aydan sonra anne st, bebeėin enerji ve besin gesi gereksinimini tam olarak karřılayamamaktadır. Tamamlayıcı beslenme dnemi, anne st ya da formula besin yetersiz kaldıėında; ocuėa ek olarak sıvı, pre, yarı katı, katı besinlerin verilmeye bařlandıėı dnemdir. Dnyta Saėlık rgt, tamamlayıcı beslenmeye 6. aydan itibaren bařlanmasını nermektedir (Barrera ve ark., 2018; WHO, 2016). Yapılan bazı alıřmalarda tamamlayıcı beslenmeye 4. aydan nce bařlamanın, 3 yařında 6 kat daha fazla obeziteye yol atıėı bildirilmiřtir (Huh ve ark., 2011; Pearce ve ark., 2013). Bir diėer alıřmada da 4. ayda her 100 kkal/gn fazla enerji alımının ocuėun 3. yařında obezite riskini %46 oranında artırdıėı saptanmıřtır (Ong ve ark., 2006). Tamamlayıcı besinlerin protein ieriėinin ocuėun gereksiniminden fazla olmasının da, ocukluk aėı obezite riskini artırdıėı bildirilmektedir. ocukluk aėında gereksinimden daha fazla protein alımının, inslin ve inslin benzeri byme faktr-1'in (IGF-1) salınımını artırıp, bymeyi hızlandırdıėı ve adipozit farklılařmasının gerekleřtiėi belirtilmiřtir (Alvisi ve ark., 2015). Birok formla

ürünün anne sütüne göre protein içeriğinin ciddi oranda yüksek olmasının çocukluk çağında obezite görülme riskini %50-80 oranında artırdığı saptanmıştır (Koletzko ve ark., 2009).

2.1.3. Çocukluk Çağı Obezitesinin Komorbiditeleri

Çocukluk çağı obezitesinin komorbiditeleri arasında; bozulmuş glukoz toleransı, diyabet, büyüme ve puberte anomalileri ve hiperandrojenizm yer almaktadır. Çalışmalara göre, hafif şişman ve obez olarak geçirilen her bir yıl diyabet riskini %14 oranında artırmaktadır (Nathan ve Noran., 2009; Pratt ve ark., 2018). Çocukluk çağında obezite problemi görülen kız çocuklarında insülin direnci ile ilişkili olan hiper androjenizm ile karakterize olan polikistik over sendromu (PKOS) görülme riski yüksektir (Anderson ve ark., 2014; Çelik ve Cinaz, 2015). Ayrıca hiperinsülinemi ile glisemik kontrol, lipid profili ve kan basıncı dengesi bozularak metabolik sendrom riski artmaktadır (Seth ve Sharma, 2013).

Nonalkolik yağlı karaciğer hastalığı (NAYKH); karaciğer yağlanması ile beraber fibrozis, siroz, inflamasyon ve son dönem karaciğer yetmezliğine kadar uzanan bir hastalık sürecidir. Son yıllarda NAYKH çocukluk çağı obezite prevalansının artması ile paralel olarak çocukluk döneminde en sık görülen hepatik hastalıklardan biridir (Clemente ve ark., 2016).

Çocukluk çağında obezite, boyun, yutak ve dilin tabanı ve çevresinde artan adipoziteye ve adeno tonsillar hipertrofiye bağlı olarak üst solunum yolunun kısıtlanmasına neden olup, obstruktif uyku apnesi gelişme riskini artırmaktadır (GarcíaCastillo ve ark., 2018).

Obezite çocukluk çağında, vasküler disfonksiyona aşırı aktifleştirilmiş renin-anjiyotensin-aldosteron sistemine ve böbrek fonksiyon bozukluklarına da neden olmaktadır (Correia-Costa ve ark., 2018). Obez çocuklarda, böbrek boyutlarında ve renal kan akımında da artış olduğu görülmektedir (Savino ve ark., 2010).

Çocukluk çağında hipertansiyon gelişme riskini artıran birincil risk faktörü obezitedir. Çocukluk döneminde görülen obezite, yetişkin çağı hipertansiyon riski ile de ilişkilidir (Estrada ve ark., 2014). Obez bir çocukta hipertansiyon gelişme ihtimali

normal ağırlıktaki çocuğa göre 2.5-3.7 kat daha fazladır (Correia-Costa ve ark., 2018).

Kardiyovasküler hastalıklar (KVH) son zamanlarda çocukluk çağı obezitesi ile beraber daha yaygın görülmektedir. Obez çocuklarda normal ağırlıktaki çocuklara göre kalp boyutu ve epikardiyal yağ birikiminin daha yüksek olduğu bildirilmiştir (Skinner ve ark., 2015). Yapılan bir çalışmada çocukluk dönemlerinde morbid obez olan yetişkin bireylerin KVH mortalite riskinin 3-5 kat fazla olduğu bildirilmiştir (Pratt ve ark., 2018).

Büyüme ve gelişme döneminde obezite kas-iskelet sistemini etkilemektedir. Bu dönemdeki ağırlık artışı büyüyen kemikler, eklemler, eklem yüzeyleri, büyüme plakaları ve epifizler arasındaki yüzeylerde basıncı artırabilmektedir. Bu aşırı basıncın uzun dönem devam etmesinin hafif şişman ve obez çocukların %50'sinde büyüme anormalliklerine neden olduğu görülmüştür (Ashley ve Gilbert, 2018; Greydanus ve ark., 2018).

Obez çocuklar normal ağırlıktaki çocuklara oranla daha düşük öz değer, öz yeterlilik ve öz saygıya sahiptir. Çocukluk çağında obeziteye ek psikolojik problemlerin gelişmesi, adolesan ve hatta yetişkinlik dönemlerine de taşınabilen çeşitli psikolojik problemler ortaya çıkabilmektedir (Greydanus ve ark., 2018). Obez çocuklarda genellikle vücut memnuniyetsizliği, depresyon, anksiyete, aşırı ağırlık kontrolü davranışları, utanç veya değersizlik hissi gibi komplikasyonlar ortaya çıkabilmektedir (Pan ve ark., 2018).

2.1.4. Çocukluk Çağı Obezitesinin Değerlendirilmesi

Çocuklar büyüme ve gelişme süreçlerinde oldukları için vücut yapıları hızlı bir şekilde değişmektedir. Çocuklarda yaşa ve cinsiyete göre yapılan büyüme gözlemleri çocukların genel sağlık ve beslenme durumlarını yansıtan iyi bir göstergedir. Çocukluk döneminde obezitenin değerlendirilmesinde en sık kullanılan yöntem BKİ olup, obezite riskinin belirlenmesinde altın standart olarak kabul edilmektedir (Hatipoğlu ve ark., 2015). Beden kütle indeksi hesaplaması, vücut ağırlığının boy uzunluğunun karesine bölünmesi ile yapılmaktadır (TÜBER, 2015; WHO 2018).

$$BKİ = \frac{\text{vücut ağırlığı (kg)}}{\text{boy uzunluğu (m)}^2}$$

BKİ değerlendirmesinde en sık kullanılan yöntemler; bireysel ve toplumsal düzeyde yüzdelik (persentil) ve/veya Z-skor değerleridir (HSGM,2019). 2017 yılında yayınlanan Amerikan Pediatri Akademisi ve Endokrin Topluluğu Klinik Uygulama Rehberinde (Endocrine Society Clinical Practice Guideline (ESCPG)), çocuklarda obezitenin değerlendirilmesinde yaşa ve cinsiyete özel BKİ persentil değerlerinin kullanılmasını önermektedir. Çocuklarda ve ergenlerde BKİ değerinin 5. persentil ve altında olması zayıf, 5-85 persentil arasında olması normal, 85-95. persentil arasında olması hafif şişman, 95. persentil ve üstünde olması ise obez olarak tanımlanmaktadır (Canadian Pediatric Endocrine Group 2018). Çocuklarda ve ergenlerde persentil değerlerine göre obezite ve dereceleri Tablo 2.1. de gösterilmiştir. Bazı ülkeler kendi ulusal referans eğrilerini ve persentil tablolarını oluşturmuştur. Ülkemizde ise çalışmalarda genellikle çocukluk çağı obezitesinin değerlendirilmesinde Türk çocukları için hazırlanan büyüme referans değerleri kullanılmaktadır (Neyzi ve ark., 2008; Öztürk ve ark., 2011) (Tablo 2.1) (Ek-1).

Tablo 2.1. Çocuklarda ve Ergenlerde Persentil Değerlerine göre BKİ Sınıflandırması

BKİ (Persentil değerlerine göre)	< 5.persentil (Zayıf)
	5-85. persentil (Normal)
	85-95. persentil (Hafif şişman)
	>95. persentil (Obez)

2.1.5. Çocukluk Çağı Obezitesinin Tedavisi

Obezitenin tedavisi, kişinin kararlı olmasına ve tedavi sürecine etkin olarak katılımını gerektiren, uzun bir süreçtir. Obezitenin etiyolojisinde pek çok faktörün etkili olması, bu hastalığın önlenmesi ve tedavisini son derece zorlaştırmaktadır. Obezitenin tedavisinde gerçekçi bir vücut ağırlığı kaybı, obeziteye ilişkin morbidite ve mortalite risklerinin azaltılması ve bireye yeterli ve dengeli beslenme alışkanlığı kazandırılarak yaşam kalitesinin yükseltilmesi hedeflenmektedir. Çocukluk çağı obezitesinin tedavisinde beslenme tedavisi, egzersiz tedavisi ve kalıcı davranış değişikliği kazandırılması önemlidir (Greydanus ve ark., 2018).

Beslenme Tedavisi

Çocukluk çağı obezitesinin tedavisinde ilk olarak çocuğun büyüme ve gelişmesi için gerekli enerji ve besin ögesi gereksiniminin sağlanarak; fazla alınan enerjinin kısıtlanması, sağlıklı beslenme alışkanlığı kazandırılması ve porsiyonların küçültülmesi hedeflenmektedir (Arslan, 2015; Caferoğlu ve ark., 2017). İki-yedi yaş arası obez çocuklarda obezitenin neden olduğu ek sağlık sorunları yoksa ağırlık kaybı yerine sağlıklı beslenme ve fiziksel aktivite alışkanlığının kazandırılması, obezitenin sebep olduğu ek bir sağlık sorunu varsa, 0.5 kg/ay ağırlık kaybı hedeflenmektedir (Selimoğlu, 2018).

Egzersiz Tedavisi

Fiziksel aktiviteyi azaltan tüm sedanter aktiviteler, çocuklarda obezitenin ortaya çıkması ile yakından ilişkilidir (Spear ve ark., 2007). Çocukluk çağında, fiziksel aktivitenin günlük en az 60 dakika orta ve yüksek şiddette yapılması ve ekran süresinin günlük 2 saatten az tutulması ve düzenli uykunun sağlanması önerilmektedir (Anderson, 2018). Amerikan Pediatri Akademisi, obez çocukların egzersiz tedavisinde kısa süreli aktiviteyle başlayıp, fiziksel aktivite sürelerinin kademeli olarak artırılmasını önermektedir (Spear ve ark., 2007).

Davranış Değişikliği Tedavisi

Çocukluk çağı obezitesinin tedavisinde hedeflenen davranış tedavilerine göre önerilen süre minimum 12 aydır. Davranış değişikliği tedavilerinin yapılmadığı ya da yarıda bırakıldığı durumlarda çocukluk çağı obezitesinin tedavisi uzun dönemde başarılı olamamaktadır (Grant-Guimaraes ve ark., 2016).

2.1.6. Çocukluk Çağı Obezitesinin Önlenmesi

Dünya Sağlık Örgütü'nün 2025 yılına kadar çocukluk çağı obezitesindeki artışın durdurulmasını öngördüğü Küresel Beslenme Hedefleri belirlemiştir. Küresel Beslenme Hedefine göre, çocukların beslenme durumlarının ve fiziksel aktivite düzeylerinin düzenli olarak izlenmesi gerekmektedir (WHO, 2014).

Amerikan Diyetetik Birliği'ne göre okullarda, çocuklara sağlıklı ve aynı zamanda kaliteli besin sunulması zorunludur. Çocukların sağlıklı beslenme alışkanlığı

kazanmalarının sağlanmasında yemekhane ve kantin koşullarının ve beslenme saatlerinin ayarlanması önemlidir. Ayrıca çocuklar için okullarda kaliteli ve çeşitli besin bulundurulması, süt ve süt ürünleri ile meyve-sebze tüketiminin artırılmasının desteklenmesi amaçlanmalıdır (TÜBER, 2015).

Dünya Sağlık Örgütü'nün çocukluk çağı obezitesinin önlenmesi eylem planında;

1. Erken dönem beslenme düzeninin ayarlanması
 - a. Fazla vücut ağırlığı ile gebe kalma veya gebelikte sağlıklı beslenme ve gebelikte fazla ağırlık kazanımının önüne geçilmesi
 - b. 2025 yılına kadar ilk 6 ay sadece anne sütü tüketiminin en az %50 'ye ulaşmasının sağlanması
 - c. Tamamlayıcı besinlerin denetiminin yapılması ve uygun görülen ürünlerin satışının sağlanması
2. Çocuklar için sağlıklı yiyecek- içecek çevresi koşullarının sağlanması
 - a. Çocuklara bazı yiyecek ve içeceklerin satışının kontrol edilmesi ve sınırlandırılması
3. Okul çağındaki tüm çocuklarda büyüme izlem ve takibinin yapılması
4. Okul ortamlarının sağlıklı hale getirilmesi vb. gibi obeziteyi önlemeye yönelik hedefler bildirilmektedir (WHO, 2018).

Ülkemizde de Türkiye Sağlıklı Beslenme ve Hareketli Hayat Programı kapsamında Çocukluk Çağı Obezitesinin Önlenmesi Eylem Planı 2019-2023 hazırlanmıştır. Eylem planında;

- a. Hayata sağlıklı bir başlangıcın desteklenmesi
- b. Okullarda ve okul öncesinde sağlıklı çevrelerin teşvik edilmesi
- c. Ailelerin bilgilendirilmesi ve güçlendirilmesi
- d. Sağlıklı seçeneklerin kolay seçenek olmasının sağlanması
- e. Çocuklara yönelik pazarlama baskısının azaltılması
- f. Fiziksel aktiviteyi geliştirmek için liderlik ve koordinasyonun sağlanması
- g. Çocuk ve adolesanların gelişiminin desteklenmesi
- h. Sürveyans, izleme, değerlendirme ve araştırmalarının desteklenmesi vb. gibi hedefler bildirilmektedir (HSHM 2019)

2.2. Yapay Zekâ

İlk olarak John McCarthy isimli Amerikalı bilgisayar ve bilişsel bilimci tarafından 1956 yılında Darmouth Konferansı'nda "Yapay zekâ" tanımı kullanılmıştır (McCarthy, 2006; Yıldırım, 2020). Yapay zekâ herhangi bir konuda tahmin veya karar verme işlemini gerçekleştiren teknolojilerin genel ismidir. Yapay zekâ, insan zekâsını taklit ederek kendisine öğretilen verilerle kendi kendini geliştirebilen, mantıklı tahminler yapan ve sonuçlar önerebilen sistemler olarak tanımlanabilir. Yapay zekâ modern bilim kurgunun bir ürünüymüş gibi algılansa da neredeyse yüzyıllık bir geçmişe dayanmaktadır. Günümüzde neredeyse hemen her alanda kullanılıp her geçen gün gelişmektedir. Örneğin yüz tanıyan telefonlar, ses tanıyarak komut alan yardımcı asistanlar, çeşitli oyunlar, sürücüsüz otomobiller, kullanımı gittikçe yaygınlaşan temizlik robotları ve insansı robotlar gibi birçok alanda günlük yaşantımızda yer almaktadır (Topol, 2019).

2.2.1. Sağlık Alanında Yapay Zekâ Uygulamaları

Yapay zekâ uygulamalarının sağlık alanında doğru tanı ve tedavi seçimi, hastalık risk tahminleri, hastalıkların sınıflandırılması, tıbbi hataların azaltılması gibi birçok alanda fayda sağladığı bilinmektedir (Topol, 2019). Sağlık alanında geliştirilen yapay zekâ uygulamaları için gerekli veri setinin oluşturulmasında sağlık verilerine birçok yöntemle ulaşılabilmektedir. Kişisel sağlık verileri; hastalara ait demografik bilgileri, sağlık çalışanlarının hastalar için tuttukları notlarını, hastalara ait görüntülemeleri, laboratuvar sonuçlarını ve tıbbi cihazlardan veya giyilebilir sensörlerden (Holter vs.) elde edilen verileri içerebilir. İnternetin gelişmesiyle birlikte bulut tabanlı sistem kapasitelerinin artışı, verilere ulaşım ve dağıtım açısından kolaylık sağlamaktadır (Tang ve ark., 2018).

Yapay zekâ uygulamalarının sağlıkta bütün alanlarda kullanılabilecek bir potansiyeli vardır. Tüm uzmanlık alanlarında yapay zekâ ve makine öğrenmesi uygulamalarının gelecekte aktif olarak kullanması kaçınılmazdır. Bu sayede medikal görüntüler, patoloji sonuçları, retina görüntüleri, cilt lezyonları, elektrokardiyogramlar ve vital bulguların kolay ve yüksek doğrulukta değerlendirilmesi mümkün olacaktır (Murdoch ve Detsky, 2013).

2.2.2 Beslenme ve Diyetetik Alanında Yapay Zekâ Uygulamaları

Bireyin diyet kontrolünü destekleyen sanal asistanlar, bilgisayar destekli menü planlama sistemleri, hastalıklara özel diyet programlarının uygulanabilirliğini destekleyen sistemler ve beslenmeye bağlı hastalıkların veya hastalık risklerinin erken teşhis edilmesini sağlayan sistemler vb. bir çok alanda yapay zekâ kullanılabilmektedir (Anselma ve ark., 2017; Garcia ve ark., 2021; Vasioloğlu ve ark.; 2018).

Yapay zekâ temelli sanal asistanlar, bir davranışın yerine getirilmesinde önemli bir rol oynayabilir. Örneğin, bir kişi bir restorana gittiğinde ve kendisine bir menü sunulduğunda, diyetine göre nasıl doğru bir karar vereceğini bilemeyebilir. Yapay zeka destekli sanal asistanlar, bireylerin diyetlerine en uygun menüyü seçebilmelerine yardımcı olabilmektedir (Mazze ve ark., 2015; Anselma ve ark., 2017).

Yapay zekâ sayesinde bir diyetisyenin menüleri planlamak için kullandığı mantık modellenerek bilgisayar destekli menü planlama sistemi gerçekleştirilebilmektedir (Petot ve ark., 1998). Yapılan bir çalışmada, bireyin enerji ve besin ögesi ihtiyaçlarını karşılayan bir günlük menü planlayan bir sistem oluşturulmuştur. Çalışmada sistemin, hastalar için özel amaçlı menü planlamasına uygulanabilir veya kurumsal kullanım için de uyarlanabilir olduğu bildirilmiştir. Yapay zekâ yaklaşımının bilgisayar destekli menü planlama için pratik kullanımının olduğu belirtilmiştir (Garcia ve ark., 2021).

Yapay zekâ hızla büyüyen bir alandır ve küresel bir problem olan diyabete yönelik uygulamaları, bu kronik hastalığın teşhis ve yönetimine yönelik yaklaşımda ciddi faydalar sağlayacak potansiyele sahiptir (İleri ve Hacıbeyoğlu 2019). Hastaların diyabeti kendi kendilerine yönetebilmeleri için yapay zekâ ile Tip 1 Diyabetli bireylerin öğünlerinin karbonhidrat miktarlarını kolayca hesaplayabilecekleri bir sistem kurulabilmektedir.

Diyabet Teknolojisi Araştırması (DTR), Bern Üniversitesi Biyomedikal Mühendisliği ARTORG Araştırma Merkezi (İsviçre) tarafından geliştirilen GoCARB isimli sistem; makine öğrenmesi ve akıllı telefon teknolojilerini kullanan

karbonhidrat sayımı için yeni bir akıllı telefon tabanlı yaklaşımdır. Bu sistem, Almanca konuşulan ülkelerde yaşayan Tip 1 diyabetli bireyler için yemeklerin karbonhidrat miktarlarının tahminini desteklemek için tasarlanmıştır (Rhyner ve ark., 2016; Bally ve ark., 2017; Vasiloglu ve ark., 2018). Bu sayede hastaların açlık ve tokluk glikoz seviyelerinin düzenlenip, glikozile hemoglobin düzeylerinin azalması ile daha iyi bir glisemik kontrol sağlayabilmek mümkündür (İleri ve Hacıbeyoğlu 2019).

Yapay zekâ destekli kurulan sistemler sayesinde obezite, diyabet, kronik böbrek yetmezliği, anemi vb. gibi beslenme ile ilişkili hastalıkların erken teşhis edilmesi veya hastalık risklerini saptamak mümkündür (Hammond ve ark., 2019; Al-Hyari ve ark., 2013).

Malezyada yapılan bir çalışmada diyabet riskinin tahmin işlemi için 140 hastaya ait 16 parametrelilik gerçek veri seti ile, %85 doğrulukta tahmin işlemi gerçekleştiren bir sistem kurulmuştur (Balakrishnan ve ark., 2012).

Kronik böbrek yetmezliğinin erken teşhisi için yapılan bir çalışmada; karar ağacı, Naive Bayes ve yapay sinir ağı algoritmalarının başarıları incelenmiştir. En yüksek başarı ile sınıflandırma işlemi %92,2 doğruluk oranı ile Karar Ağacı algoritmasının gerçekleştirdiği görülmüştür (Al-Hyari ve ark, 2013). Salekin ve Stankovic (2016) tarafından yapılan bir çalışmada kronik böbrek hastalığının tespitinde k-en yakın komşu ve karar ağacı algoritmalarının başarıları test edilmiştir. Karar ağacı algoritmasının hastalığın tespitinde k-en yakın komşu algoritmasından daha iyi performans gösterdiği belirtilmiştir.

Kadınlardaki demir eksikliği anemisinin teşhisine yönelik yapılan bir çalışmada kadınlardaki demir eksikliği anemisinin teşhisi için %92,97 doğrulukta sınıflandırma işlemi gerçekleştiren karar ağacı algoritması ile sistem geliştirilmiştir (Yurtay ve ark., 2012).

Yapılan bir çalışmada elektronik sağlık kayıtlarında bulunan bebeklik ve çocukluk dönemindeki bilgileri içeren verilerden obezite riskini tahmin edebilen bir sistem önerilmiştir. Sistemin kurulumunda %86 doğruluk oranı ile sınıflandırma işlemi gerçekleştiren lojistik regresyon algoritması kullanılmıştır (Hammond ve ark.; 2019).

Adnan ve arkadaşlarının (2012) yaptıkları bir çalışmada, 5-7 yaş arasındaki 200 çocuğa ait demografik özellikler, doğum haftası, doğum ağırlığı, anne sütü alma durumu, fiziksel aktivite düzeyi, televizyon ve internet karşısında geçirilen süre, şekerli içecek içme durumu, kahvaltı tüketim sıklığı, fast-food tüketim sıklığı, ailede obezite varlığı gibi obezite ile ilişkili temel risk faktörlerini kaydedilmiştir. Bu veri seti ile yapılan denetimli öğrenme çalışmasında obezite için kurulan tahmin modelinde genetik algoritma kullanılmıştır.

Yapılan bir çalışmada ise obezite riskinin erken teşhisi için 2-5 yaş arasındaki 238 çocuğa ait ekran süresi, demografik özellikler, beslenme alışkanlıkları ve antropometrik ölçümleri ile makine öğrenmesi yöntemleri geliştirilmiştir. Çalışmada çocukluk çağı obezitesinin tahmininde en yüksek doğruluk oranının karar ağacı algoritmasına ait olduğu bildirilmiştir. (Wiechmann ve ark., 2017).

Bulut'un (2017) yaptığı bir çalışmada okul çağı çocuklarına ait antropometrik özellikler, psikolojik faktörler, ebeveynlere ait özellikler, aktivite ve ekran süresi, öğün sıklığı ve besin tüketim sıklığı ile alakalı 29 faktör makineye öğretilerek obezite için tahmin işlemi gerçekleştiren hibrit bir model önerilmiştir. Çalışmada en yüksek sınıflandırma başarısının karar ağacı algoritmasına ait olduğu görülmüştür. Karar ağacı algoritmasının MCC değerinin 0,667 ve k-en yakın komşu algoritmasının MCC değerinin 0.469 olduğu bildirilmiştir.

Bu çalışmalar gösteriyor ki; yapay zekâ ile geliştirilen sistemler; çağımızda sağlık bakım hizmetlerinin kalitesini geliştirebilecek ve hastalıkların erken teşhis edilmesine yardımcı olacak potansiyel sahiptir. Hastalıkların erken teşhisi ise tedavi için harcanan zaman ve sağlık bakım maliyetlerinin azalmasını sağlayabilecektir.

2.3. Makine Öğrenmesi

Yapay zekâ herhangi bir konuda tahmin işlemi gerçekleştiren sistemin genel adıdır. Makine öğrenmesi ise insanların öğrenme süreçlerinden esinlenerek ortaya çıkan bir yapay zekâ alanıdır. Makine öğrenmesi, bilgisayarlar doğrudan programlanmadan, kendilerine insan gözlemlerinin bilgi ve veri formunda verilerek, insanlar gibi öğrenmesi bilimidir. Makine öğrenmesinin temel işlevi örneklerden sonuç elde

etmektedir (Alpaydın,2010). Makine öğrenmesi veriyi tek bir matematiksel modelle öğrenme işlemi gerçekleştirmektedir. (Şekil 2.1) (Chollet, 2017).



Şekil 2.1. Yapay Zekâ, Makine Öğrenmesi

2.3.1. Makine Öğrenmesi Uygulama Süreci

Web ortamı üzerinde doğru şekilde çalışan bir makine öğrenmesi süreci için gereken adımlar Çapraz Endüstri Standart Süreç Modeli (Cross Industry Standart Processfor Data Mining (CRISP-DM)) ile takip edilmektedir (Huber ve ark., 2018; Shearer, 2000). CRISP-DM modeli; problemin tanımlanması, veriyi anlama, veri hazırlama, modelleme, modelin değerlendirme ve seçimi ve modelin uygulamaya geçirilmesi olmak üzere altı adımdan oluşmaktadır (Şekil 2.2).

3. Adım. Veri Hazırlama (Data Preprocessing);

Makine öğrenmesi sürecine başlamadan önce verinin analizler için en uygun formata getirilmesi önemlidir. (Şahinarslan, 2019). Veri seti içerisindeki aykırı veya eksik verilerin belirlenmesi, en yararlı öznitelikleri seçme ve bulma süreci makine öğrenmesi modelinin performansını ciddi anlamda etkilemektedir. Araştırmacı tarafından hazırlanan özgün veri setlerinde aykırı değer görülme olasılığı hazır veri setlerine göre daha düşüktür (Atan, 2020).

4. Adım. Modelleme;

Karmaşık ve çok sayıda farklı nitelikten oluşan ham veri hazır hale getirildikten sonra konuyla alakalı sınıflandırma algoritmaları kullanarak makine öğrenmesi işlemi gerçekleştirilerek modeller kurulmaktadır. Bu süreçte oluşturulan modeller, verinin içindeki olası esas gizli düzen ya da örüntüyü yakalamak için kullanılmaktadır. Amaç bu modeller arasından en iyi sonucu veren modelin seçilmesidir (Şahinarslan, 2019).

5. Adım. Model Değerlendirme ve Seçimi;

Her bir modelin başarısının değerlendirilmesi için geliştirilen bir takım performans değerlendirme metrikleri ve yöntemleri bulunmaktadır (Kartal, 2015).

6. Adım. Modelin Uygulamaya Geçirilmesi;

Bu sürece kadar herhangi bir sorun veya eksiklik görülüyorsa modelin uygulamaya geçirilmesi sağlanır (Shearer, 2000; Kartal, 2015).

Makine öğrenmesi algoritmaları ile hastalıkların teşhisi veya hastalık risk tahmininde, uzmanların kararına destek olabilecek veya uzman yokluğunda karar verme sürecinde yardımcı olabilecek önemli çalışmalar yapılmaktadır. Makine öğrenmesi algoritmaları ile eğer doğru veri seçilir ve doğru tekniklerle işlenerek hazır hale getirilirse yüksek doğrulukta kararlar alabilecek otomatik bir sistemden bahsetmek mümkündür. Makine öğrenmesinin bir alt dalı olan sınıflandırma algoritmaları da bu alanda kullanılmaktadır. Sınıflandırma algoritmaları makinenin eğitilmesi için verilen verileri kullanarak kendisini eğitir. Eğitim tamamlandıktan sonra sınıflandırma algoritması daha sonra olası durumları için tahmin işlemi gerçekleştirir. (Komesli, 2007; Özata ve Aslan, 2004; Tian-en ve ark., 2009).

2.3.2. Makine Öğrenmesinde Öğrenme Yöntemleri

Verinin yapısına göre öğrenme yöntemleri değişmektedir. Öğrenme yöntemi belirlendikten sonra makine öğrenmesi için en doğru modeli seçmek daha kolay olur (Ericson ve ark., 2017). Verinin yapısına göre seçilen öğrenme yöntemi belirlendikten sonra algoritma seçimi yapılır (Okur, 2020). Makine öğrenmesinde yer alan yöntemler ve algoritmalar için üç öğrenme yöntemi vardır

- a. Denetimli Öğrenme (Supervised Learning)
- b. Denetimsiz Öğrenme (Unsupervised Learning)
- c. Takviyeli / Pekiştirmeli Öğrenme (Reinforcement Learning)

a. Denetimli Öğrenme (Supervised Learning);

Denetimli öğrenme yönteminde; kullanılan algoritmalar sayesinde sistem bir veri kümesinden, sisteme verilen öznitelikler ile sonuç değeri arasındaki ilişkiyi öğrenir. Öğrenme bir kez gerçekleştiğinde sisteme gönderilen her yeni veri için geçmişte öğrendiği veriler üzerinden çıkarım yapılarak tahmin işlemi gerçekleştirir. Eğitim için verilen veriler ne kadar doğru ve fazla sayıda olursa yapılan tahminler o oranda doğru çıkmaktadır. Tahmin için kullanılan veriler etiketlenmişse bu denetimli öğrenme yönteminin kullanıldığını göstergesidir (Okur, 2020). Denetimli öğrenmede amaç hangi sınıfa ait olduğu belli olan etiketli verilerin hangi çıktı değerine karşılık geldiğinin belirlenmesidir. Oluşturulan model ile elde edilen sonuç arasındaki fark hata oranını ifade etmektedir. Bu oran her zaman en aza indirgenmeye çalışılır (Kavuncu,2018). Bu yöntem sağlık hizmetlerinde ve diğer alanlarda kullanılan en etkili ve köklü yöntemdir.

Denetimli öğrenme yöntemleri; regresyon (regression) ve sınıflandırma (classification) olmak üzere iki grupta incelenir.

Regresyon; Bağımlı bir değişkenin davranışının bağımsız bir veya daha fazla değişken üzerinden modellenmesidir. Bağımsız değişkenlere, bağımlı bir değişkeni etkiledikleri derecede bir katsayı atanır (Özçift, 2014).

Sınıflandırma; Verinin içerdği ortak özellikleri kullanarak söz konusu verilerin ayrıştırılması işlemi sınıflandırma olarak adlandırılır (Özkan, 2013). Sınıflandırma; etiketlenmiş olan verilerin özniteliklerinden öğrenip, sınıfı belli olmayan verilerin özniteliklerinden belirli bir sınıfa veya gruba atanması işlemidir (Can, 2020). Sınıflandırma, hangi sınıfa ait olduğu bilinmeyen bir kayıt için bir sınıf belirlenmesi sürecidir. Örneğin, bir sınıflandırma işlemi ile hastaların kanser olma riski “yüksek” veya “düşük” olarak sınıflandırılabilir (Özkan, 2013).

Sınıflandırmanın amacı; verilerin ortak özelliklerinin incelenerek yeni verinin bir sınıfa atanması işleminin yapılmasıdır. Örneğin; malzeme, hava durumu tespiti, maillerin spam tespiti gibi; sağlık, finans, inşaat vb. gibi hemen hemen her alanda sınıflandırma işlemlerinde makine öğrenmesinden faydalanılmaktadır (Ünsal,2011).

Makine öğrenmesinin sınıflandırma algoritmalarının her veri kümesi için optimum sonucu vermemesi nedeniyle pek çok algoritma geliştirilmiştir (Göker, 2019). Çeşitli sınıflandırma algoritmaları ile modeller kurularak modellerin doğruluk derecesi belirlenir ve belirlenen bu değer ne kadar yüksekse model o kadar başarılı kabul edilir (Aydın,2020).

Sınıflandırma problemlerinde en sık kullanılan denetimli makine öğrenmesi algoritmaları lojistik regresyon (logistic regression), Naif Bayes (NaiveBayes) k-en yakın komşu (k-nearest neighbourhood), destek vektör makinesi (support vector machines), yapay sinir ağları (artificial neural network) ve karar ağaçları (decision tree) algoritmalarıdır.

b. Denetimsiz Öğrenme (Unsupervised Learning);

Veriler hakkında herhangi bir sonuç değeri vermeden veriler arasındaki ilişkiyi kendi kendine öğrenen bilgisayar programlarıdır. Yoğunluk tahmini olarak da adlandırılan denetimsiz makine öğrenmesi; sınıfı olmayan verilerle, bu verilere benzer özelliklere sahip verilerin gruplandırılması amacıyla kullanılan, girdi verileri için uygun bir gösterim biçimi belirleyen bir öğrenme türüdür. Bu öğrenme modelinin, sadece girdi değerlerinden oluşması sebebiyle, girdilere karşılık gelen bir çıktı (sınıf) değeri yoktur. Bu yüzden girdilerin hangi sınıfa ait olduğu bilinmemektedir (Fatima ve Pasha, 2017; Öztemel, 2012).

c. Takviyeli / Pekiştirmeli Öğrenme (Reinforcement Learning)


Denetimli öğrenme gibi, etiketli veriler kullanılarak oluşturulan bir sınıflandırıcı ile başlar. Bununla birlikte; sistem daha sonra etiketlenmemiş verileri alır ve bu verileri denetimsiz öğrenme ile benzer şekilde daha iyi karakterize ederek sınıflandırmayı daha da geliştirmeye çalışır (Özçift, 2014).

2.3.3. Makine Öğrenmesinde Sınıflandırma Algoritmaları

Lojistik Regresyon (Logistic Regression)

Lojistik regresyon, iki ya da daha fazla değişken arasındaki ilişkiyi açıklamak için kullanılan bir araştırma yöntemidir (Yeşilnacar ve Topal, 2005). Multinomial lojistik regresyon ikiden fazla sınıfın olduğu olayların sınıflandırılmasında, ikili lojistik regresyon ise sadece iki sınıfın olduğu durumlarda kullanılır (Aydın 2020; Coşkun ve ark., 2004).

Lojistik regresyon algoritmasının basitleştirilmiş çizimi Şekil 2.3.'te gösterilmiştir.



Şekil 2.3. Lojistik Regresyon Basitleştirilmiş Çizimi (Koçak ve ark.,2019)

Turuncu ve mor daireler farklı grupları temsil etmektedir. Lojistik regresyonda, bir veya daha fazla bağımsız değişkenle elde edilen sonuç belli bir olasılığın üstündeysen mor, altındaysa turuncu grup olarak sınıflandırılır.


Naif Bayes (Naive Bayes)

Naive Bayes (NB) istatistiksel bir sınıflama yöntemidir. Olasılık hesaplamalarının kullanıldığı Bayes teoremine dayanır. Bir sınıftaki belirli bir özelliğin başka herhangi bir özelliğe bağlı olmadığını varsayarak sınıflandırma yapan ve veri seti içerisindeki sınıfların yapısını öğrenerek buna uygun bir şekilde yeni bir gözlem geldiğinde hangi sınıfa ait olduğunu belirleyen basit ve etkili bir yöntemdir. “X olasılığının Y durumundan meydana gelme olasılığı nedir?” sorusuna cevap arar (Silahtaroglu, 2008).

Bayes teoreminde hesaplamalar koşullu olasılıklar ile bağımlı değişkenler üzerinden yapılır. Koşullu olasılık kavramı gerçekleşmiş bir olay üzerinden yeni bir durum meydana gelme olasılığına dayanır. Örneğin; daha önce yapılmış olan maçlar incelenerek çeşitli etkenler göz önüne alındığında bir maçın galibiyetle ya da mağlubiyetle bitmesi durumu tahmin edilebilir (Kavuncu, 2018).

Naif Bayes algoritmaları verileri hızlı bir şekilde eğitilmesi ve yüksek doğruluk oranları vermesi sebebiyle oldukça avantajlıdır. Fakat sınıflandırma problemlerinin karmaşık olması durumunda Naif Bayes algoritması yetersiz kalmaktadır (Uzun, 2007).

Lojistik regresyon algoritmasının basitleştirilmiş çizimi Şekil 2.4.’te gösterilmiştir.



Şekil 2.4. Navie Bayes Basitleştirilmiş Çizimi (Koçak ve ark.,2019)


Naif Bayes algoritması tüm özelliklerin sonuca veya sınıf öngörüsüne eşit katkıda bulunduğunu kabul eder. Turuncu ve mor yuvarlaklar, farklı sınıflardaki örnekler için farklı olasılık düzeylerini temsil eder.

k- En Yakın Komşu Algoritması (k-Nearest Neighbourhood)

k-en yakın komşu (kNN), bir nesnenin hangi sınıfa ait olduğunu belirlemek amacıyla kullanılan, birbirine olan yakınlık derecelerine göre sınıflandırma işlemi yapan algoritmadır (Özkan, 2008). k-en yakın komşu algoritmalarının temel amacı, sınıfı belli olmayan her bir nesnenin, o sınıf dışındaki bütün nesneler ile karşılaştırılması ve bu karşılaştırma sonucunda, kendisine en yakın k sınıftaki örneklerin ortalaması ile birlikte bir gruba atanmasıdır (Özkan 2008). Nesnelerin birbirine olan uzaklığını hesaplarken genellikle Jaccard uzaklığı, Öklid uzaklığı, Manhattan uzaklığı, basit eşleşme uzaklığı formülleri kullanılmaktadır (Lantz, 2013; Özkan, 2008).

k-en yakın komşu uygulamalarının sade ve anlaşılır olması ve verilerin eğitim sürecinin kısa olması gibi güçlü yanları vardır. Fakat sınıflandırma sürecinin yavaş olması, yüksek hafızalı bilgisayarlar gerektirmesi, kayıp verilerin işlem yükünü arttırması gibi pek çok zayıf yönü de bulunmaktadır. k-en yakın komşu uygulamalarında ilk olarak eğitim verilerinden öğrenme gerçekleştirilir ve bu öğrenme sonucunda bir k değeri belirlenir. Bu değer, sistem için uygun kümeleme sayısını ifade eder. Ardından veriler bu değere göre sınıflanır (Lantz, 2013).

k-en yakın komşu algoritmasının basitleştirilmiş çizimi Şekil 2.5’de gösterilmiştir.



Şekil 2.5. K-En Yakın Komşu Algoritmasının Basitleştirilmiş Çizimi (Koçak ve ark.,2019)


kNN’de en yakın üç komşu göz önüne alındığında, bilinmeyen nesne (sarı üçgen) turuncu dairelerle temsil edilen sınıfa atanırken, en yakın beş komşu durumunda mor daireler sınıfına atanır.

Destek Vektör Makineleri (Support Vector Machines)

Destek vektör makinesi (DVM), sınıfları birbirinden ayırt etmek için bir düzlem belirten, eski veriler yardımıyla iki veya daha fazla sınıfa ayırmak ve tahmin etmek için sıklıkla kullanılan bir makine öğrenmesi algoritmasıdır (Güner ve Çomak, 2011; Yılmaz, 2013).

Destek vektör makinesi uygulamalarında amaç; veri kümesinin lineer olarak ayrılabilir durumuna bakarak karar verebilmesi için, doğru şekilde gruplama yapılmasını sağlamaktır. Bu nedenle DVM algoritmalarında amaç hiper düzlemde iki sınıfı birbirinden ayıran en iyi fonksiyonu tahmin etmek hedeflenir (Demolli ve ark., 2019; Yılmaz, 2013). En uygun hiper düzlem, farklı sınıflara ait vektörler arasındaki uzaklığın en fazla düzeyde olması yoluyla elde edilir. Destek vektörleri ise hiper düzlemin iki tarafındaki en yakın vektörlerdir (Koçak ve ark, 2019).

Destek vektör makinesi algoritmasının basitleştirilmiş çizimi Şekil 2.6.’da gösterilmiştir.



Şekil 2.6. Destek Vektör Makinesinin Basitleştirilmiş Çizimi (Koçak ve ark.,2019)

Algoritma orijinal veriyi (soldaki çizim) sınıfları ayıran optimal düzlem (mavi çizgi) ve vektörler (mavi kesikli çizgiler) ile farklı bir alana (sağdaki çizim) taşır. Mor ve turuncu daireler farklı grupları temsil etmektedir.


Yapay Sinir Ağları (Artificial Neural Network)

Yapay sinir ağları (YSA) insan beyninin sinir sistemiyle benzer şekilde çalışan bir algoritmadır (Kavuncu,2018; Öztemel, 2012). Yapay sinir ağları algoritmasının amacı; insana özel karar verme, yorum yapma, ilişki kurma, yeni bilgileri keşfetme ve üretme gibi insan beyninde öğrenme ile gerçekleşen bu yetenekleri otomatik olarak gerçekleştirmektir (Öztemel, 2012; Uğur ve Kınacı, 2006). YSA, eğitim sürecinde kullanılan veri setindeki veriler arasındaki ilişkiyi öğrenerek, tahmin işlemi yapmaktadır. Bunun için oluşturulan sinir ağı olayla ilgili örneklerle eğitilip tahmin yapılabilecek yeteneğe kavuşturulur.

Yapay sinir ağları, sinir hücrelerinin birbirleriyle olan farklı birleşimlerinden meydana gelir. Çoğunlukla katmanlar halinde düzenlenebilmekte ve donanım şeklinde elektronik devreler ile birlikte tasarlanabilmektedir (Haykin, 1999).

Deneyimler sayesinde öğrenebilme ve bilgiyi saklama yeteneğine sahip olan YSA algoritmasında model kurulurken, verilerin bir kısmı yapay sinir ağına iletilir. Veri yapay sinir ağına iletildikten sonra yapay sinir ağı çıktı değeri konusunda bir tahminde bulunur. Tahmin edilen değer ve gerçek değer karşılaştırılır. Sonuçta ağ herhangi bir başka faaliyet göstermiyorsa bulunan tahmini değer doğrudur (Marakas, 2003; Uğur ve Kınacı, 2006).

Yapay sinir ağı algoritmasının basitleştirilmiş çizimi Şekil 27.'de gösterilmiştir.



Şekil 2.7. Yapay Sinir Ağının Basitleştirilmiş Çizimi (Erickson ve ark., 2017)

Yapay sinir ağıları girilen verilere göre gizli bir katmanda sınıflandırma için bir fonksiyon üretir ve buna göre çıkış katmanında sonucu verir.

İnsan beyninin yapısından ilham alınarak tasarlanan yapay sinir ağıları; doğal dil işleme, ses işleme, görüntü işleme, tıp ve haberleşme gibi pek çok alanda yaygın olarak kullanılmaktadır (Kavuncu, 2018).

Karar Ağaçları (Decision Tree)


Karar ağaçları; problemlerin çözümünde ağaç biçiminde bir yapı oluşturarak sınıflandırma, kümeleme ve tahmin etme işlemlerini gerçekleştiren bir algoritmadır (Keskin, 2018; Rocaklı, 2008).

Karar ağaçları, diğer algoritmalara göre veri setlerindeki karmaşık yapıları basit karar yapılarına dönüştürebilmesi açısından daha anlaşılır ve yorumlanabilir (Keskin, 2018).

Karar ağaçları kök, düğüm, dal ve yaprak olmak üzere bölümlere ayrılır ve sınıflandırma için kök kısımdan yaprak kısma doğru hareket halindedir (Kutlugün, 2017; Uzun, 2007). Karar ağacında düğüm kısmı soruları, dal kısmı bu sorulara verilen yanıtları, yaprak kısmı ise kararlaştırılan sınıfı temsil etmektedir (Yılmaz, 2013).

Karar ağaçları kökü tepede olan ters bir ağaç gibidir. Karar verirken etkisi en fazla olan değişken en tepede olan değişkendir. Verilerin tamamı düğümden yani karar verme noktalarından geçer. Ağaç modeli oluşurken kökten itibaren bir gövdeden iki veya daha fazla dala ayrılır. Daha fazla bölünemeyen bir yaprak (düğüm) elde edilene kadar bu durum devam eder (Murphy, 2012; Linoff ve Berry, 2004).

Karar ağacı algoritmasının basitleştirilmiş çizimi Şekil 2.8.'de gösterilmiştir.



Şekil 2.8. Karar Ağacı Modellemesi (Erickson ve ark., 2017)

Karar ağacı algoritmaları, sınıflandırmada en doğru ve en basit karar noktalarını oluşturur ve en kolay yorumlanabilir modelleri sağlar.

Karar ağaçlarını oluşturabilmek için, hangi değişkenden başlanılacağı önemli bir karardır. Bu sebeple entropi, kazanç ölçütü ve kazanç oranı gibi parametreler kullanılmaktadır. (Loh, 2011; Wu ve ark., 2006). Karar ağacı temelli analizlerden, parametrik model kurulumunda yararlanmak için fazla sayıda değişkenler içerisinde en önemlilerini seçmede, yalnızca belirli bir gruba ait olan ilişkileri tanımlamada, farklı vakaların düşük, orta, yüksek risk grupları olarak kategorize edilmesi vb. gibi pek çok alanda sıklıkla yararlanılmaktadır (Akpınar, 2000).

2.3.4. Makine Öğrenmesinde Modellerin Başarı Ölçütleri

Algoritmaların başarısı değerlendirilirken doğruluk oranı (accuracy rate), duyarlılık (sensitivity, recall): hassasiyet (precision), F-ölçütü (f-score) ve kappa istatistik değerleri incelenir. Modelin başarısı, doğru sınıfa atanan örnek sayısı ve yanlış sınıfa atılan örnek sayısı ile de ilişkilidir. Test sonucunda ulaşılan sonuçların başarısı karmaşıklık matrisi ile ifade edilebilir. Karmaşıklık matrisinde kolonlar modelin tahmin ettiği sayıları satırlar ise test kümesindeki örneklerle ait gerçek sayıları ifade eder (Powers, 2011).

Karmaşıklık Matrisi (Confusion Matrix)

Karmaşıklık matrisi, gerçek değerleri bilinen test verisi üzerinde gerçekleştirilen bir sınıflandırma işleminin performansını tanımlamak için kullanılan bir tablodur (Tablo 2.2).

Tablo 2.2 Karmaşıklık Matrisi Modeli

		Tahmin	
		Pozitif	Negatif
Gerçek	Pozitif	TP (Doğru Pozitif)	FN (Yanlış Negatif)
	Negatif	FP (Yanlış Pozitif)	TN (Doğru Negatif)

Doğru Pozitifler (TP): Gerçekte değeri 1 ve tahmin edilen sonuç değerinin de 1 olduğu örneklerdir.

Doğru Negatifler (TN): Gerçekte değeri 0 ve tahmin edilen sonuç değerinin de 0 olduğu örneklerdir.

Yanlış Pozitifler (FP): Gerçekte değeri 0 ancak tahmin edilen sonuç değerinin 1 olduğu örneklerdir.

Yanlış Negatifler (FN): Gerçekte değeri 1 ancak tahmin edilen sonuç değerinin 0 olduğu örneklerdir.

Bazı doğruluk metrikleri karmaşıklık matrisinden hesaplanır. TP, TN, FP ve FN değerleri ile hesaplanan bu metrikler aşağıda verilmiştir.

$$TOPLAM = TP + TN + FP + FN$$

$$GERÇEK POZİTİFLER = TP + FN$$

$$GERÇEK NEGATİFLER = TN + FP$$

Doğruluk Oranı (Accuracy Rate): Modelin performansının ölçümünde kullanılan en basit ve popüler metriktir, modelin doğruluk oranıdır.

$$\frac{TP+TN}{TP+TN+FP+FN}$$

Duyarlılık (Sensitivity, recall): Gerçekte pozitif olan bir değerin, test sonucunun da pozitif olması ihtimalidir. 0 ile 1 arasında değişir, değer 1'e yaklaştıkça, modelin performansının yükseldiği anlamına gelir.

$$\frac{TP}{TP + FN}$$

Hassasiyet (Precision): Ayrılan tüm sınıf değerlerinden, ne kadarının doğru olarak tahmin edildiğinin bir ölçüsüdür. Mümkün olduğu kadar yüksek olmalıdır. "Pozitif tahmin edici değer" olarak da bilinir.

$$\frac{TP}{TP + FP}$$

F-ölçütü (F-Measure): Duyarlılık ve kesinlik metriklerinin harmonik ortalamasıdır. Her iki değeri de bir arada ele alma imkânı sağlamaktadır. Makine öğrenmesi algoritmalarının yorumlanmasında önemlidir.

$$\frac{2 \times Recall \times Precision}{Recall + Precision}$$

Matthews Korelasyon Katsayısı (Matthews Correlation Coefficient-MCC): makine öğrenmesinde ikili (iki sınıflı) sınıflandırma işlemlerinin performanslarının bir ölçütüdür. TP, TN, FP, FN tüm sonuçları hesaba katar genellikle sınıflar çok farklı boyutlarda olsa bile kullanılabilir dengeli bir ölçüt olarak kabul edilir. Gerçek değerlerle tahmin verileri arasındaki korelasyon (*phi-coefficient*) ilişkisini değerlendirir.

$$\frac{(TP \times TN) - (FP \times FN)}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}$$

Kappa istatistik (kappa statistic); tahmin edilen değerler ile gerçek değerlerin uyumunun güvenilirliğinin ölçütüdür.

$$\frac{\text{Gözlenen Doğruluk} - \text{Beklenen Doğruluk}}{1 - \text{Beklenen Doğruluk}}$$

2.4. Sistemin Geliştirilmesinde Kullanılan Programlar

2.4.1. Waikato Bilgi Analizi Ortamı

Waikato Bilgi Analizi Ortamı (The Waikato Environment for Knowledge Analysis, WEKA) Yeni Zelanda Waikato Üniversitesi tarafından oluşturulmuş makine öğrenmesi konusunda kullanılan, paketlerden birinin ismidir. WEKA programı açık kaynak kodlu olup Java tabanlı bir uygulama sunmaktadır. Veri ön işleme, regresyon, kümeleme, sınıflandırma gibi algoritmaları içerir. Algoritmalar seçilerek veriler üzerine uygulanmakta ve en doğru sonucu veren algoritma seçilebilmektedir (Şeker, 2013; Waikato Üniversitesi, 2014.WEKA. 3.8.5 Sürümü. Yeni Zelanda.)

2.4.2. Python

Python, ilk sürümü 1991’de Hollandalı bilgisayar mühendisi Guidovan Rossum tarafından geliştirilmeye başlanmış bir programlama dilidir. Python hızlı ve dinamik bir dil olup, aynı zamanda ücretsizdir. Günümüzde Python, kolay kullanımı ve beraberinde geniş standart kütüphaneler getirdiği için oldukça popülerdir ve büyük kurumların da arasında olduğu yaygın bir kullanıcı kitlesi vardır. Python ile temel bilimsel hesaplama için çeşitli kütüphaneler kullanılmaktadır (Cengiz, 2020)

Numpy; verilerin bilimsel metotlarla hesaplanmasını kolaylaştıran bir Python kütüphanesidir (Cengiz, 2020).

Keras; Python programlama dili üzerine yazılmış bir derin öğrenme kütüphanesidir (Toğaçar ve Ergen, 2019).

Pandas; veri yapıları ve veri işleme araçlarının kullanılabilmesini sağlayan, csv ve txt uzantılı dosyaları kolay işlemeye olanak veren bir kütüphanedir (Cengiz, 2020).

Sklearn; Python programlama dili üzerine yazılmış makine öğrenmesi modelleri geliştirmek için kullanılan bir kütüphanedir. Regresyon ve sınıflandırma işlemleri için kullanılan pek çok algoritmaya sahiptir (Cengiz, 2020).

Flask; Python programlama dilinde geliştirilen modellerin web ortamında kullanımını sağlayan kütüphanedir (Ronacher A. Flask kütüphanesi).

2.4.3. Visual Studio Code

Visual Studio Code, Microsoft tarafından geliştirilen bir kaynak kodu düzenleyicisidir. Hata ayıklama, gömülü Git kontrolü, söz dizimi vurgulama, python dilinde akıllı kod tamamlama ve kod yeniden yapılandırma desteği içerir (Microsoft Visual Studio, 2010).

2.4.4. Heroku

Heroku 2007 yılında kurulan bulut tabanlı ücretsiz bir platform servisi. Günümüzde Java, Node.js, Scala, Clojure, Python, PHP ile Go dilleri ve platformlarını desteklemektedir. Geliştirilen yazılım projeleri Heroku bulut sağlayıcısına aktararak yazılımın web tabanlı olarak çalışması sağlanır (<https://www.heroku.com/>).

2.4.5. GitHub

Bir proje üzerinde yapılan değişiklikleri adım adım kaydeden ve istenirse bunu internet üzerinde depoda (repository) saklanmasını ve yönetimini sağlayan bir sistemdir. Ayrıca Git, bir projede çalışırken yaptığınız değişiklikleri görebilmenizi, eski haline erişebilmenizi sağlar. Bu şekilde projenin her adımına erişebilir ve geliştirme süreçlerini sağlıklı bir şekilde izleyebiliriz. Ayrıca bir projede birden fazla kişi çalışması durumunda da aynı dosya üzerinde yapılan değişikliklerin sorun çıkmadan kontrol edilebilmesine, projelerin güncel versiyonlarına ulaşabilmeye yardımcı olur. Bu tür avantajlar sağlaması nedeniyle birçok yönden fayda sağlar ve hız artırır (Ateş, 2020).


3. GEREÇ VE YÖNTEMLER

Bu çalışma Erciyes Üniversitesi Sosyal ve Beşeri Bilimler Etik Kurulu'nun 28/08/2020 tarih ve 128 sayılı onayı (Ek-2) ve Tokat İl Milli Eğitim Müdürlüğü'nün 30/09/2020 tarih ve 27001677-44-E.13826234 sayılı araştırma izni (Ek-3) ile yapılmıştır. Araştırmanın evrenini 2020-2021 eğitim öğretim yılında Tokat ili Merkez ilçesinde resmi ve özel anaokullarına devam eden 4-6 yaş aralığındaki bütün çocukların ebeveynleri (n=885) oluşturmaktadır.

Çalışma iki aşamadan oluşmaktadır;

- İlk aşamada makine öğrenmesi yaklaşımları ile çocukluk çağı obezitesi için web tabanlı dinamik bir erken uyarı sistemi geliştirilmiştir. Makine öğrenmesi sürecinde WEKA, 3.8.5 ve Visual Studio Code 1.66.2 programları kullanılmıştır.
- İkinci aşamada geliştirilen web tabanlı sistem ile çocukların obezite risk düzeyleri saptanmıştır.

Çalışmanın akış diyagramı Şekil 3.1'de gösterilmiştir.




Şekil 3.1. Çalışmanın Akış Diyagramı

3.1. Makine Öğrenmesi Süreci

Çalışmanın ilk aşaması olan makine öğrenmesi sürecinin doğru şekilde gerçekleşmesi için gereken adımlar Çapraz Endüstri Standart Süreç Modeli (Cross-Industry Standard Process for Data Mining (CRISP-DM) ile takip edilmiştir (Huber ve ark.,2019).

Makine öğrenmesi süreci gerçekleştirilirken uygulanan adımlar Şekil 3.2’de gösterilmiştir.



Şekil 3.2. Makine Öğrenmesi Süreci Gerçekleştirilirken Uygulanan Adımlar

3.1.1. Problemin Tanımlanması

Obezite, dünya genelinde en sık görülen sağlık sorunlarından biridir. Çocukluk çağında obezite özellikle okul öncesi çağda 4–6 yaş aralığında çok hızlı gelişmektedir. Çocukluk çağındaki obezitenin yetişkinlik dönemine de yansıdığı bilinmektedir (HSGM 2019). Bu nedenle çocukluk çağında obezitenin erken dönemde tespit edilebilmesi veya çocukların obezite riskinin saptanması obezitenin tedavisi ve obeziteden korunmak için zamanında önem alınabilmesi için oldukça önemlidir. Çocukluk döneminde önlenemediği veya tedavi edilemediği takdirde obezitenin yetişkinlik döneminde tedavisi daha da zorlaşmaktadır (Günöz, 2010).

Çocukluk çağında obezitenin tespiti veya riskinin saptanması hayli zordur. Ancak bu günlerde birçok hastalık teşhisinde ve hastalık riskinin hesaplanmasında makine öğrenmesi, derin öğrenme gibi yapay zekâ destekli yöntemler yaygın olarak kullanılmaktadır. Bu teknolojiler, çocukluk çağı obezitesinin teşhisinde veya gelecek dönemler için obezite risk düzeylerinin saptanmasında akıl yürütme özelliğine sahip akıllı sistemlerin kurulmasında kullanılabilmektedir. Bu sayede aileler çocukların obezite risklerini erken dönemde saptayabilir ve gerekli önlemlerin alınması için sağlık profesyonellerine başvurabilirler (Chollet, 2017; Hal Daumé III, 2012).

Bu çalışmanın amacı, çağımızın hızla artan problemi olan obezitenin henüz ortaya çıkmadan saptanmasını sağlayacak, kolay kullanım imkânı sunan, web tabanlı dinamik bir sistem geliştirilmesi ve böylece aileler tarafından çocukluk çağında obezite henüz gelişmeden önlem alınmasına katkı sağlanmasıdır.

3.1.2. Veriyi Anlama

Bu çalışmada çocukluk çağı obezitesi ile ilişkisi olan parametreler literatürden faydalanarak saptanmıştır. Bunun sonucunda toplam 35 parametre belirlenerek “Çocukluk Çağı Obezite Riski ile İlişkili Risk Faktörleri Anket Formu” oluşturulmuştur (Ek-4).

Veri setinde kullanılan parametreler çocuğun; cinsiyeti, yaşı, vücut ağırlığı, boy uzunluğu ve travmatik olay yaşama durumu, ailede obezite varlığı, ailenin gelir durumu, annenin eğitim düzeyi, annenin mesleği, babanın mesleği, çocuğun gün

içerisindeki toplam aktivite süresi, çocuğun gün içerisinde bilgisayar/tablet/telefon başında geçirdiği toplam süre, çocuğun gün içerisinde televizyon başında geçirdiği toplam süre, çocuğun kahvaltı, öğle, akşam, kuşluk, ikindi ve yatsı öğünlerini tüketim sıklığı, çocuğun süt ve süt ürünleri, et ve et ürünleri, tahıl ve tahıl ürünleri, meyve-sebze, bal-reçel-pekmez, tereyağı, fastfood, hamur işi, cips-kızartma vb., gazlı/şekerli içecekler, çikolata-bisküvi vb. tüketim sıklıkları, çocuğun doğum haftası, çocuğun doğum ağırlığı, çocuğun tek başına anne sütü alma süresi, çocuğun toplam anne sütü alma süresi ve çocuğun formüla/mama tüketme durumudur.

07/10/2020-31/03/2021 tarihleri arasında Tokat İl Milli Eğitim Müdürlüğüne bağlı tüm anaokullarındaki 4-6 yaş arasındaki zayıf-normal ağırlıkta ve hafif şişman-obez çocukların verileri toplanmıştır. Çalışmaya katılmayı kabul eden ebeveynlere öncelikle çalışma hakkında bilgi verilmiş ve “Ayrıntılı Bilgilendirme Formu” ,“Çalışma Katılım Kabul Formu” ve “Veli Onam Formu” okutulup imzalatılmıştır (Ek-5, Ek-6, Ek-7). Çocukların vücut ağırlıkları, kalibrasyonu yapılmış Seca (Almanya) baskül ile düz zeminde ve ince kıyafetlerle ölçülmüş, boy uzunlukları ise Seca (Almanya) boy ölçer ile düz zeminde Frankfort düzleminde ölçülmüştür. Vücut ağırlığı boy uzunluğunun karesine bölünerek BKİ değerleri hesaplanmıştır. Ölçümler ve hesaplamalar araştırmacı tarafından yapılmış ve kaydedilmiştir. Anket formu araştırmacı tarafından çalışmaya katılmaya gönüllü olan aileler ile yüz yüze görüşme tekniği ile doldurulmuştur. Konuşma, işitme, görme veya zihinsel engeli olup, iletişim kuramayacak ailelerin çocukları ile 4 yaşın altında ve 6 yaşın üstünde olan çocuklar çalışmaya dahil edilmemiştir.

Anket formundaki özniteliklerin sahip olduğu niteliksel veriler çocukluk çağı obezitesi ile ilişki düzeylerine göre sayısal değerler verilerek nicelleştirilmiş ve araştırmacı tarafından hazırlanan excel dosyasına kaydedilmiştir. Çocukluk çağı obezitesi ile ilişkili her bir parametre, veri seti için bir öznitelik olarak düşünülmüştür. Böylece 491 zayıf-normal ağırlıkta çocuk ve 294 hafif şişman-obez çocuk olmak üzere toplam 785 çocuğun verileri ile 35 boyutlu özgün bir veri seti oluşturulmuştur.

Anket sorularındaki öznitelikler sayısal değerlere dönüştürülmüştür. Veri setinin özellikleri ve detayları Tablo 3.1 de gösterilmiştir.

Tablo 3.1 Veri Setinin İerdiği Öznitelikler ve Özniteliklere Atanan Değerler

ÖZNİTELİKLER	SEÇENEKLER	DEĞER
Cinsiyet	Erkek	0
	Kız	1
Yaş	4	
	5	
	6	
Vücut ağırlığı	Kilogram cinsinden kaydedildi	
Boy uzunluğu	Metre cinsinden kaydedildi	
Çocuğun travmatik olay yaşama durumu	Hayır	0
	Evet	1
Ailede obezite hikâyesi	Hayır	0
	Evet	1
Ailenin gelir durumu	Gelir giderine eşit	0
	Gelir giderinden az	1
	Gelir giderinden fazla	2
Anne eğitim durumu	Lisansüstü	0
	Lisans	1
	Lise	2
	İlköğretim	3
Annenin mesleği	Sağlık çalışanı	0
	Memur	1
	Diğer	2
	Ev hanımı	3
Babanın mesleği	Sağlık çalışanı	0
	Memur	1
	Diğer	2
	Çalışmıyor	3
Çocuğun gün içerisinde aktivite süresi	2 saatten fazla	0
	1-2 saat	1
	1 saatten az	2
Çocuğun gün içerisinde bilgisayar/tablet/telefon başında geçirdiği süre	2 saatten fazla	0
	1-2 saat	1
	1 saatten az	2
Çocuğun gün içerisinde televizyon başında geçirdiği süre	2 saatten fazla	0
	1-2 saat	1
	1 saatten az	2
Kahvaltı öğünü tüketim sıklığı	Her gün	0
	Arada bir	1
	Hiç	2
Öğle öğünü tüketim sıklığı	Her gün	0
	Arada bir	1
	Hiç	2
Aksam öğünü tüketim sıklığı	Her gün	0
	Arada bir	1
	Hiç	2
Kuşluk öğünü tüketim sıklığı	Her gün	0
	Arada bir	1
	Hiç	2
İkinci öğünü tüketim sıklığı	Her gün	0
	Arada bir	1
	Hiç	2

Tablo 3.1 Devam Veri Setinin İerdiği Öznitelikler ve Özniteliklere Atanan Değerler

ÖZNİTELİKLER	SEENEKLER	DEĞER
Yatsı öğünü tüketim sıklığı	Her gün	2
	Arada bir	1
	Hi	0
Süt ve ürünleri tüketim sıklığı	Her gün	0
	Arada bir	1
	Hi	2
Et ve ürünleri tüketim sıklığı	Her gün	0
	Arada bir	1
	Hi	2
Tahıl ve tahıl ürünleri tüketim sıklığı	Arada bir	0
	Hi	1
	Her gün	2
Meyve ve sebze tüketim sıklığı	Her gün	0
	Arada bir	1
	Hi	2
Bal, reel, pekmez vb. tüketim sıklığı	Hi	0
	Arada bir	1
	Her gün	2
Tereyağı tüketim sıklığı	Hi	0
	Arada bir	1
	Her gün	2
Fastfood tüketim sıklığı	Hi	0
	Arada bir	1
	Her gün	2
Hamur isi tüketim sıklığı	Hi	0
	Arada bir	1
	Her gün	2
Cips/kızartma vb. tüketim sıklığı	Hi	0
	Arada bir	1
	Her gün	2
Gazlı/şekerli içecekler tüketim sıklığı	Hi	0
	Arada bir	1
	Her gün	2
ikolata, bisküvi, kraker vb. tüketim sıklığı	Hi	0
	Arada bir	1
	Her gün	2
Çocuğun doğum haftası	37-40 hafta arası	0
	37 hafta altı	1
	40 hafta üstü	2
Çocuğun doğum ağırlığı	2500-4000 gram arası	0
	2500 gram ve altı	1
	4000 gram ve üstü	2
Çocuğun sadece anne sütü alma süresi	6 ay	0
	6 aydan az	1
Çocuğun toplam anne sütü alma süresi	12 aydan fazla	0
	12 aydan az	1
Çocuğun formula tüketme durumu	Hayır	0
	Evet	1
Sınıf	Zayıf-Normal	0
	Hafif şişman-Obez	1

Tablo 3.2 Sınıflara Atanan Değerler ve Verilerin Sınıflara Göre Dağılımı

Sınıflar	Sınıf Değeri	Açıklama	Veri Sayısı	Toplam Veri Sayısı
Obezite Riski Düşük	0	Yaşa ve cinsiyete göre BKİ değerleri 85. persentil altındaki zayıf ve normal ağırlıktaki çocuklar	491	785
Obezite Riski Yüksek	1	Yaşa ve cinsiyete göre BKİ değerleri 85. persentil üstündeki hafif şişman-obez çocuklar	294	

Veri setindeki sınıf kategorisi için çocukların BKİ değerleri hesaplanarak yaşa ve cinsiyete göre persentil değeri tablosunda 85. persentil ve üstünde yer alan zayıf ve normal ağırlıktaki çocuklar “obezite riski yüksek” ve 85. persentil altındaki Hafif şişman-obez çocuklar “obezite riski düşük” olarak kaydedilmiştir (Tablo 3.2) (Neyzi ve ark 2008).

3.1.3. Veri Hazırlama

Veri hazırlama adımı CRISP-DM sürecinin en önemli adımlarındandır, çünkü bu adımda ham veri seti daha anlamlı hale getirilmektedir. Veri temizleme işlemi yapılmaktadır yani modelin oluşmasına engel olacak eksik değerler tamamlanmakta ve aykırı veriler temizlenmektedir. Veri setindeki özniteliklerin değişken aralıkları çok genişse normalizasyon işlemi uygulanabilir. Veri tipleri birbirlerine dönüştürülerek veri seti daha anlaşılır ve kullanılabilir hale getirilir. Örneğin cinsiyet parametresinde “erkek” ve “kız” değerleri “0” ve “1” değerlerine dönüştürülür.

Bu çalışmada excel formatındaki veri seti “csv.” formatına dönüştürülerek WEKA 3.6.1.2 programında kullanılacak hale getirilmiştir. WEKA programında Explorer modülü seçilerek bundan sonraki tüm işlemler bu modül üzerinde gerçekleştirilmiştir. Explorer modülü kullanıcıya sınıflandırma, kümeleme ve nitelik seçme imkânı sağlayan araştırmaya yönelik modüldür (Şekil 3.3).




Şekil 3.3. WEKA 3.8.5 Giriş Ekranı

“csv.” formatına dönüştürülen veri seti *Preprocess/Open File* adımları ile programa yüklenmiştir. Open file butonuyla açılan “.csv” uzantılı dosyalar, istenildiğinde “save” butonu ile “.arff” uzantılı dosya türlerine dönüştürülebilir. Preprocess panelinde her özneliğin cevapları ve ağırlıkları görülebilmektedir. Ayrıca istenilen özneliğin istatistikleri veya tüm özneliklerin özellikleri tek bir pencerede görülebilmektedir. WEKA programında, analiz sırasında istenilmeyen öznelikler silinebilmekte ve düzenlenebilmektedir.

Veri seti ön işlemden geçirilerek hazır hale getirilmiştir. Veri ön işleme sürecinde *preprocess/filters/unsupervised/attribute/numerictonominal* adımları izlenerek veri setindeki sınıf değeri altındaki “0” ve “1” verileri numerik yapıdan “obezite riski düşük” ve “obezite riski yüksek” olarak nominal yapıya dönüştürülmüştür. Veri setindeki öğrenme işleminde kullanılacak diğer tüm parametreler için her bir boyuttaki değerler normalize edilmiştir ve 0-1 aralığına çekilmiştir, çünkü her bir özneliğin aldığı sayısal değer aralıkları farklıdır. Aşırı uç değerler öğrenme sürecini olumsuz etkilemektedir. Bu nedenle verilerdeki düzensiz dağılımlar sebebiyle oluşabilecek problemlerin önüne geçmek için veri setindeki tüm veriler normalize

edilmiştir. Normalizasyon işlemi *preprocess/filters/unsupervised/attribute/normalize* adımları ile gerçekleştirilmiştir (Şekil 3.4). Ancak karar ağacı uygulamasında algoritmanın daha doğru ve tutarlı çalışabilmesi için veri setindeki veriler numerik yapıdan nominal yapıya çevrilmiştir. Böylece karar ağacı algoritmasının karakteristiği doğru şekilde yansıtılmış olmaktadır.



Şekil 3.4. WEKA programında normalizasyon işlemi

3.1.4. Modelleme

WEKA Explorer modülünde “Classify” paneli sınıflandırma algoritmalarının uygulandığı kısımdır. Bu panelde model geliştirilirken çapraz doğrulama (cross validation) veya yüzde olarak ayırma (percentage split) seçilebilmektedir. Bu seçenekler ile kurulan modelin doğruluğu test edilmektedir (Şeker 2013).

Çapraz doğrulama ile veri kümesi eşit boyutta parçalara bölünmektedir. Algoritma her seferinde 1 parçayı modelin testi için, n-1 adet parçayı ise modelin öğrenilmesi için kullanmaktadır. Yüzde ayırma yöntemi ise veri kümesinin isteğe bağlı oranda yüzdesini modelin öğrenme işlemine, geri kalan yüzdelik kısmını da modelin test

edilmesi işlemine ayırarak analiz yapmaktadır. “*Use training set*” seçeneği ile verinin tamamı test kümesi için kullanılabilir (Şeker 2013).

Çalışmamızda denetimli öğrenme yöntemlerinden sınıflandırma işlemi gerçekleştiren makine öğrenmesi algoritmaları ile modeller kurulmuştur. Model kurulurken makineye her bir verinin 35 özniteliğini içeren eğitim verileri ve hangi gruba ait olduğu bilgisi verilmiştir. Hafif şişman-obez çocukların verileri “obezite riski yüksek” ve zayıf-normal ağırlıktaki çocukların verileri “obezite riski düşük” olarak sınıflandırılmıştır. Test sürecinde makine öğrenmesi algoritmaları ile kurulan modeller test verilerindeki 35 özniteliği değerlendirerek hafif şişman-obez çocukların özelliklerine benzeyenleri “obezite riski yüksek” ve normal ağırlıktaki çocukların özelliklerine benzeyen verileri “obezite riski düşük” olarak sınıflandıracaktır.

Bu çalışmada hazır hale getirilen veri seti 10 parça çapraz doğrulama (cross validation) yöntemi ile analiz edilmiştir. Çapraz doğrulama işleminde veri kümesi öncelikle belirlenen 10 alt küme sayısına bölünmüştür. Sonrasında ise her parça 1 kez test kümesi olarak kullanılarak sistem eğitilip ardından da test kümesi ile test edilmiştir. Çıkan test sonuçlarının ortalaması alınarak sistemin performansı belirlenmiştir.

WEKA programında classify panelinden algoritmalar seçilerek modeller kurulmuştur. Çalışmamızda sınıflandırma problemlerinde en yaygın kullanılan makine öğrenmesi yöntemlerinden Naive Bayes (NB), IBk (k-en yakın komşu, k-nearestneighbour), Multilayer perception (Yapay sinir ağları-YSA), J48 (karar ağacı), Logistic (lojistik regresyon) ve LibSVM (destek vektör makinesi) algoritmaları kullanılmıştır (Şeker 2013).

3.1.5. Model Değerlendirme ve Seçimi;

Algoritmaların deneysel analizleri yapıldıktan sonra her algoritmanın sınıflandırma başarıları; doğruluk oranı (accuracy rate), duyarlılık (sensivity, recall), hassasiyet (percision), F-ölçütü (f-score), kappa istatistik (kappa statistic) metriklerinin değerleri ve karmaşıklık matrisi tabloları ile değerlendirilmiştir. Sistemin geliştirilmesinde en yüksek başarı ile sınıflandırma işlemi gerçekleştiren karar ağacı algoritmasının kullanılmasına karar verilmiştir.

3.1.6. Modelin Uygulamaya Geçirilmesi;

Çalışmanın kodlama işlemleri Visual Studio Code 1.66.2 programında Python dilinde gerçekleştirilmiştir. Weka üzerinden gerçekleştirilen deneysel değerlendirmelerde çocukluk çağı obezite riskinin en iyi karar ağacı algoritması ile tespit edildiği görülmüştür. Bu sebeple, modelin dinamik olarak kullanılabilmesi için python dilinde karar ağacı uygulaması geliştirilmiştir.

Çalışmamızın python dilinde kodlama uygulamasının adımları;

- Masaüstünde “Yeni Klasör” oluşturuldu ve içerisinde “csv.” uzantılı excel dosyası eklendi.
- Visual Studio Code programında *File/Open Folder/Yeni Klasör* adımları ile yeni kütüphane oluşturuldu.
- Programda açılan Yeni Klasör Kütüphanesinin içerisine “model.py” ve “app.py” adında iki yeni dosya oluşturuldu.
- “model.py” dosyasında karar ağacı algoritması ile model kuruldu (Şekil 3.5).
 - Pandas, keras ve numpy kütüphaneleri çağırıldı ve Run/Start Debugging adımları ile kütüphaneler yüklendi.
 - `importnumpy`
 - `importkeras`
 - `importpandas`
 - Veri seti test-train olarak bölündü. Yüzde ayırma (percentage split) yöntemi seçilerek verilerin %75’i eğitim ve %25’i test verisi olarak belirlendi.
 - `fromsklearn.model_selectionimporttrain_test_split`
 - `X_train, X_test, y_train, y_test = train_test_split(predictors, target, train_size=0.75, test_size=0.25)`
 - Karar ağacı algoritması yüklendi.
 - `fromsklearnimporttree`
 - `fromsklearn.treeimportDecisionTreeClassifier`

- Doğruluk metrikleri yüklendi.
 - `fromsklearn.metricsimportconfusion_matrix`
 - `fromsklearn.metricsimportaccuracy_score`
 - `importpickle`
- Veri seti yüklendi.
 - `concrete_data = pandas.read_csv("b_diyetisyen.csv")`
 - `concrete_data.head()`
 - `predictors = concrete_data.drop(columns='Sinif')`
 - `predictors.head()`
 - `target = concrete_data['Sinif']`
- Model değişkeni ile karar ağacı uygulaması oluşturuldu. Karar ağacının en iyi sınıflandırma işlemini gerçekleştirebilmesi ve karar ağacının düzenli bir şekilde çalışabilmesi için entropi kriteri kullanıldı.
 - `Model=DecisionTreeClassifier(criterion='entropy',random_state=2)`
- Eğitim aşaması ile model eğitildi ve eğitme işlemi sonrasında modelin skorları ekrana yazdırıldı.
 - `model.fit(X_train, y_train)`
 - `model.score(X_train,y_train)`
- Test verilerinin tahminleme işlemi gerçekleştirildi ve ekranda gösterildi.
 - `predictions = model.predict(X_test)`
 - `predictions`
- Modelin başarısını gösteren metrikler çağırıldı.
 - `fromsklearnimportmetrics`
 - `importnumpy as np`

- `print('MeanAbsoluteError:',
metrics.mean_absolute_error(y_test, predictions))`
- `print('MeanSquaredError:',
metrics.mean_squared_error(y_test, predictions))`
- `print('RootMeanSquaredError:',
np.sqrt(metrics.mean_squared_error(y_test, predictions)))`
- `fromsklearn.metricsimportclassification_report,
confusion_matrix, accuracy_score`
- `print(accuracy_score(y_test, predictions))`

- Kurulan modelin web ortamında çalışabilmesi için hafızaya alınmasını ve yeni verinin model içerisinde açılmasını sağlayan fonksiyonlar kuruldu. Ve *Run/Start Debuging* adımları gerçekleştirildi ve bunun sonucunda “model.pkl” adında yeni bir dosya oluştu.

- `pickle.dump(model,open('model.pkl','wb'))`
- `model = pickle.load(open('model.pkl','rb'))`

- Yeni girilen her verinin kurulan modelde tahmin edilmesi sağlandı.
- `new_record =
np.array([[0,6,15,1.00,1,1,1,2,2,3,2,2,1,2,1,0,2,2,2,2,0,0,2,2,2,
0,2,2,2,1,2,1,1,1,0]])`
- `predict_result=model.predict(new_record)`
- `print(predict_result)`

```

model.py > ...
1  import numpy
2  import keras
3  import pandas
4
5  from sklearn.model_selection import train_test_split
6
7  from sklearn import tree
8  from sklearn.tree import DecisionTreeClassifier
9
10 from sklearn.metrics import confusion_matrix
11 from sklearn.metrics import accuracy_score
12 import pickle
13
14 concrete_data = pandas.read_csv("b_diyetisyen.csv")
15 concrete_data.head()
16 predictors = concrete_data.drop(columns='Sinif')
17 predictors.head()
18 target = concrete_data['Sinif']
19
20 X_train, X_test, y_train, y_test = train_test_split(predictors, target, train_size=0.75, test_size=0.25)
21
22 model = DecisionTreeClassifier(criterion='entropy', random_state=2)
23 #train model
24 model.fit(X_train, y_train)
25 #print score
26 model.score(X_train, y_train)
27
28 #predict X_test data
29 predictions = model.predict(X_test)
30 predictions
31
32 #Serializing the model
33 pickle.dump(model, open('model.pkl', 'wb'))
34 model = pickle.load(open('model.pkl', 'rb'))
35
36 new_record = np.array([[0,6,15,1.00,1,1,1,2,2,3,2,2,1,2,1,0,2,2,2,2,0,0,2,2,2,0,2,2,2,1,2,1,1,1,0]])
37 predict_result=model.predict(new_record)
38 print(predict_result)

```

Şekil 3.5. Karar Ağacı Algoritması ile Kurulan Modelin Kodları

- “app.py” dosyası içinde kurulan modelin web tabanlı hale getirilmesi için gerekli kodlamalar yapıldı (Şekil 3.6).
 - Python flask kütüphanesi kurularak yapılan model web ortamına taşındı.
 - *from flask import Flask, render_template, url_for, request, jsonify*
 - *import numpy as np*
 - *import pickle*
 - *app = Flask(__name__, static_url_path='/static')*
 - *model = pickle.load(open('model.pkl', 'rb'))*

- Web sitesi kullanıcı ara yüzünü oluşturmak için “index.html” dosyası yüklendi (Şekil 3.7).

- `@app.route('/')`
 - `defhome():`
 - `returnrender_template('index.html')`

- Kullanıcı ara yüzünde bulunan soru formu kullanıcı tarafından doldurulduktan sonra verilerin web ortamından tahmin edilmesi için kurulan modele gönderilmesini ve tahmin işleminin gerçekleşmesini sağlayan kod yazıldı.

- `@app.route('/predict',methods=['POST'])`
 - `defpredict():`
 - `int_feature = [x for x in request.form.values()]`
 - `print(int_feature)`
 - `int_feature = [float(i) for i in int_feature]`
 - `final_features = [np.array(int_feature)]`
 - `prediction = model.predict(final_features)`
 - `output = prediction`
 - `print(output)`
 - `Return render_template('index.html',prediction_text= output)`

- Karar ağacı algoritması ile kurulan model tarafından yapılan tahmin sonucunun kullanıcı ara yüzündeki ekrana yansımısını sağlayan kod yazıldı.

- `@app.route('/predict',methods=['POST'])`
 - `defresults():`
 - `data = request.get_json(force=True)`
 - `prediction = model.predict([np.array(list(data.values()))])`
 - `output = prediction[0]`
 - `returnjsonify(output)`
 - `if __name__ == '__main__':`
 - `app.run(debug=True)`

```

app.py > ...
1  ✓ from flask import Flask ,render_template,url_for,request, jsonify
2  import numpy as np
3  import pickle
4
5  ▶ app = Flask(__name__,static_url_path='/static')
6  model = pickle.load(open('model.pkl', 'rb'))
7
8  # Home Route
9  @app.route('/')
10 ✓ def home():
11     |     return render_template('index.html')
12
13 # prediction
14 @app.route('/predict',methods=['POST'])
15 ✓ def predict():
16     |     int_feature = [x for x in request.form.values()]
17     |     print(int_feature)
18     |     int_feature = [float(i) for i in int_feature]
19     |     final_features = [np.array(int_feature)]
20     |     prediction = model.predict(final_features)
21
22     |     output = prediction
23     |     print(output)
24
25     |     return render_template('index.html',prediction_text= output)
26
27 @app.route('/predict',methods=['POST'])
28 ✓ def results():
29     |
30     |     data = request.get_json(force=True)
31     |     prediction = model.predict([np.array(list(data.values()))])
32
33     |     output = prediction[0]
34     |     return jsonify(output)
35
36 ✓ if __name__ == '__main__':
37     |     app.run(debug=True)

```

Şekil 3.6. Sistemin Web Alt Yapısının (@app) Kodları

```
index - Not Defied
Dosya Düzen Biçim Görünüm Yardım
<h2>Makine Öğrenmesi Algoritmaları ile Çocukluk Çağı Obezite Riskinin Saptanması</h2>
</center>
<p style="text-align: justify; line-height: 1.5em;">Çocukluk döneminde obezite riskinin erken teşhisinin sağlanması yetişkinlikte obeziteye yakalanma ihtimalini azaltabilme
Hazırlanan model ile çocukluk çağı obezite riskinin tahmininde Karar ağacı algoritması kullanılmaktadır.
</p>
<center class="text-success"><h5>Modelimizin Doğru Tahmin Oranı %94'dür.</h5></center>
</div>
<form action="{ url_for('predict') }}" method="post" >
<div class="yanyana">
<div class="kutu">
<p>1. Çocuğunuzun cinsiyeti nedir? </p>
<label><input type="radio" name="Cinsiyet" value="0" checked="">Erkek</label>
<label><input type="radio" name="Cinsiyet" value="1">Kız</label>
</div>
</div>
<div class="bitir"></div>
<div class="yanyana">
<div class="kutu">
<p>2. Çocuğun yaşını giriniz </p>
<input type="text" style="width: 50%; height: 20px;" name="Yas" placeholder="Çocuğun yaşını giriniz" required="true">
</div>
<div class="kutu">
<p>3. Çocuğun kilosunu giriniz </p>
<input type="text" class="form-control" style="width: 50%; height: 20px;" name="kilo" placeholder="Çocuğun kilosunu giriniz" required="true">
</div>
<div class="kutu">
<p>4. Çocuğun boyunu giriniz </p>
<input type="text" style="width: 50%; height: 20px;" name="boy" placeholder="Çocuğun boyunu giriniz" required="true">
</div>
</div>
<div class="bitir"></div>
<div class="yanyana">
<div class="kutu">
<p>5. Ailenin Başından çocuğu etkileyecek üzücü-travmatik bir olay geçti mi?</p>
<label><input type="radio" name="travmatik_olay" value="0" checked="">Hayır</label>
<label><input type="radio" name="travmatik_olay" value="1">Evet</label>
</div>
<div class="kutu">
<p>6. Ailede fazla kilolu - obez birey var mı?</p>
</div>
</div>
```

Şekil 3.7. index.html Dosyasından Bir Kesit

- Web sitesinin dinamik bir yapıda olması için gerekli adımlar gerçekleştirildi.
 - Python dilinde kodlaması gerçekleştirilen bu işlemlerin web ortamında dinamik bir şekilde her zaman çalışabilmesini sağlayan sanal makinenin kurulum işlemi için “Terminal” bölümünde kodlamalar gerçekleştirildi.
 - *Pipinstall --user virtualenv*
 - *Python -m virtualenv venv*
 - Web ortamında çalışan sistem için heroku.com sayfasında üyelik işlemleri tamamlandı.
 - Git CMD uygulaması açıldı ve kodlamalar gerçekleştirildi.
 - heroku.com sitesinde tarif edilen adımlar gerçekleştirildi (Şekil 3.8).

Install the Heroku CLI

Download and install the [Heroku CLI](#).

If you haven't already, log in to your Heroku account and follow the prompts to create a new SSH public key.

```
$ heroku login
```

Create a new Git repository

Initialize a git repository in a new or existing directory

```
$ cd my-project/  
$ git init  
$ heroku git:remote -a obezite
```

Deploy your application

Commit your code to the repository and deploy it to Heroku using Git.

```
$ git add .  
$ git commit -am "make it better"  
$ git push heroku master
```



You can now change your main deploy branch from "master" to "main" for both manual and automatic deploys, please follow the instructions [here](#).

Existing Git repository

For existing repositories, simply add the `heroku` remote

```
$ heroku git:remote -a obezite
```

Şekil 3.8. Heroku Kodları

Bu adımların sonucunda karar ağacı algoritması ile çocukluk çağı obezite riskini tahmin eden web tabanlı dinamik sistemin kurulumu tamamlandı (Şekil 3.9, Şekil 3.10).

- Web uygulaması yerelde (localhost) çalıştırıldığında kullanıcıyı Şekil 3.11 ve Şekil 3.12’de gösterildiği gibi bir ara yüz karşılamaktadır. Kullanıcı hazırlanan ara yüzde obezite riskini hesaplamak istediği çocukla ilgili soruları cevaplayarak sayfanın sonundaki “Tahmin” butonuna tıkladığında girilen veriler karar ağacı algoritması ile kurulan modelde değerlendirilecek ve “obezite riski yüksek” veya “obezite riski düşük şekilde iki sonuç çıkacaktır.

Makine Öğrenmesi Algoritmaları ile Çocukluk Çağı Obezite Riskinin Saptanması

Çocukluk döneminde obezite riskinin erken teşhisinin sağlanması yetişkinlikte obeziteye yakalanma ihtimalini azaltabilmektedir. Hazırlanan model ile çocukluk çağı obezite riskinin tahmininde Karar ağacı algoritması kullanılmaktadır.

Modelimizin Doğru Tahmin Oranı %94'dür.

1. Çocuğunuzun cinsiyeti nedir? ☒ Erkek ☐ Kız		
2. Çocuğun yaşını giriniz 	3. Çocuğun kilosunu giriniz 	4. Çocuğun boyunu giriniz
4. Ailenin Başından çocuğu etkileyecek üzücü-travmatik bir olay geçti mi? ☒ Hayır ☐ Evet	6. Ailede fazla kilolu - obez birey var mı? ☒ Hayır ☐ Evet	7. Ailenin aylık gelir durumu nedir? ☒ Gelir giderine eşit ☐ Gelir giderinden az ☐ Gelir giderinden fazla
8. Annenin eğitim durumu nedir? ☒ Lisansüstü ☐ Lisans ☐ Lise ☐ İlköğretim	9. Annenin mesleği nedir? ☒ Sağlık Personeli ☐ Memur ☐ Diğer ☐ Çalışmıyor	10. Babanın mesleği nedir? ☒ Sağlık Personeli ☐ Memur ☐ Diğer ☐ Çalışmıyor
11. Çocuğun gün içerisinde sportif ve bedensel aktivitelerle geçirdiği toplam süre ne kadar? ☒ 2 saat ve üstü ☐ 1-2 saat ☐ 1 saat altı	12. Çocuğun gün içerisinde bilgisayar/tablet karşısında geçirdiği toplam süre ne kadar? ☒ 1 saat altı ☐ 1-2 saat ☐ 2 saat üstü	13. Çocuğun gün içerisinde televizyon karşısında geçirdiği toplam süre ne kadar? ☒ 1 saat altı ☐ 1-2 saat ☐ 2 saat üstü
14. Çocuğun kahvaltı öğünü tüketim durumu? ☒ Hergün ☐ Arada bir ☐ Hiç	15. Çocuğun öğle öğünü tüketim durumu? ☒ Hergün ☐ Arada bir ☐ Hiç	16. Çocuğun akşam öğünü tüketim durumu? ☒ Hergün ☐ Arada bir ☐ Hiç
17. Çocuğunuz kızlık ara Ahi (inisi) tüketim durumu?	18. Çocuğunuz ikindi ara Ahi (inisi) tüketim durumu?	19. Çocuğunuz üste ara Ahi (inisi) tüketim durumu?

Şekil 3.9. Web Sayfası Görünümü 1/2

14. Çocuğun kahvaltı öğünü tüketim durumu? ☒ Hergün ☐ Arada bir ☐ Hiç	15. Çocuğun öğle öğünü tüketim durumu? ☒ Hergün ☐ Arada bir ☐ Hiç	16. Çocuğun akşam öğünü tüketim durumu? ☒ Hergün ☐ Arada bir ☐ Hiç
17. Çocuğunuz kuşluk ara öğünü tüketim durumu? ☒ Hergün ☐ Arada bir ☐ Hiç	18. Çocuğunuz ikindi ara öğünü tüketim durumu? ☒ Hergün ☐ Arada bir ☐ Hiç	19. Çocuğunuz yatış ara öğünü tüketim durumu? ☒ Hiç ☐ Arada bir ☐ Hergün
20. Çocuğunuzun süt ve süt ürünleri tüketim sıklığı nedir? ☒ Hergün ☐ Arada bir ☐ Hiç	21. Çocuğunuzun et ve et ürünleri tüketim sıklığı nedir? ☒ Hergün ☐ Arada bir ☐ Hiç	22. Çocuğunuzun tahıl ürünleri tüketim sıklığı nedir? ☒ Arada bir ☐ Hiç ☐ Hergün
23. Çocuğunuzun meyve ve sebze tüketim sıklığı nedir? ☒ Hergün ☐ Arada bir ☐ Hiç	24. Çocuğunuzun bal-ecel-pekmaz tüketim sıklığı nedir? ☒ Hiç ☐ Arada bir ☐ Hergün	25. Çocuğunuzun tereyağı tüketim sıklığı nedir? ☒ Hiç ☐ Arada bir ☐ Hergün
26. Çocuğunuzun fastfood tüketim sıklığı nedir? ☒ Hiç ☐ Arada bir ☐ Hergün	27. Çocuğunuzun hamur işi tüketim sıklığı nedir? ☒ Hiç ☐ Arada bir ☐ Hergün	28. Çocuğunuzun chips-potates kızartması tüketim sıklığı nedir? ☒ Hiç ☐ Arada bir ☐ Hergün
29. Çocuğunuzun gazlı içecek - hazır Meyve suyu tüketim sıklığı nedir? ☒ Hiç ☐ Arada bir ☐ Hergün	30. Çocuğunuzun çikolata-Bisküvi-kraaker vb. tüketim sıklığı nedir? ☒ Hiç ☐ Arada bir ☐ Hergün	
31. Çocuk kaç haftalıkken dünyaya gelmiştir? ☒ 37-40 hafta arası ☐ 37 hafta altı ☐ 40 hafta üstü	32. Çocuğun doğum ağırlığı kaç gramdır? ☒ 2500-4000 gram arası ☐ 2500 gram altı ☐ 4000 gram üstü	
33. Çocuğun sadece anne sütü tüketme süresi ne kadardır? ☒ 6 ay ☐ 6 aydan az	34. Çocuğun toplam anne sütü tüketme süresi ne kadardır? ☒ 12 aydan fazla ☐ 12 aydan az	35. Çocuğun formüla mama tüketme durumu nedir? ☒ Hayır tüketmedi ☐ Evet tüketti

Tahmin Etmek İçin Tıklayınız
Tahmin

Şekil 3.10. Web Sayfası Görünümü 2/2

Makine Öğrenmesi Algoritmaları ile Çocukluk Çağı Obezite Riskinin Saptanması

Çocukluk döneminde obezite riskinin erken teşhisinin sağlanması yetişkinlikte obeziteye yakalanma ihtimalini azaltabilmektedir. Hazırlanan model ile çocukluk çağı obezite riskinin tahmininde Karar ağacı algoritması kullanılmaktadır.

Modelimizin Doğru Tahmin Oranı %94'dür.

Obezite Riski Düşük



Şekil 3.11. Web Uygulaması Kullanıcı Ara Yüzü Sonuç Ekranı 1

Makine Öğrenmesi Algoritmaları ile Çocukluk Çağı Obezite Riskinin Saptanması

Çocukluk döneminde obezite riskinin erken teşhisinin sağlanması yetişkinlikte obeziteye yakalanma ihtimalini azaltabilmektedir. Hazırlanan model ile çocukluk çağı obezite riskinin tahmininde Karar ağacı algoritması kullanılmaktadır.

Modelimizin Doğru Tahmin Oranı %94'dür.

Obezite Riski Yüksek



Şekil 3.12 Web Uygulaması Kullanıcı Ara Yüzü Sonuç Ekranı 2

Web tabanlı dinamik sitemde, girilen her yeni veri arka planda çalışan karar ağacı algoritması ile kurulan modelde işlenerek tahmin işlemi gerçekleştirilmektedir.

Geliştirilen dinamik sistemin web adresi;

<https://cocukluk-cagi-obezitesi.herokuapp.com/>

3.2. Geliştirilen Sistemi Uygulama Süreci

Çalışmanın ikinci aşamasında; karar ağacı algoritması ile geliştirilen çocukluk çağı obezite riskini tahmin edebilen web tabanlı dinamik sistem geliştirilmiştir. Geliştirilen sistemi test etmek amacı ile deneysel değerlendirmelerde kullanılmamış 2 anaokulundaki çocukların (n=100) ebeveynleri ile yüz yüze görüşülmüştür. Bu aşamada araştırmacının gözetiminde ailelerden web tabanlı sistemi kullanarak çocuklarının obezite risklerinin tahmin işlemini gerçekleştirmeleri istenmiştir. Ailelerin sisteme verdikleri cevaplar ve sistemin verdiği sonuç değerleri araştırmacı tarafından kaydedilmiştir. Sistemin “obezite riski yüksek” ve “obezite riski düşük” olarak tahmin ettiği çocukların yaşa ve cinsiyete göre BKİ değerleri ve obezite riski ile ilişkili özniteliklerinin gruplara göre dağılımı istatistik olarak değerlendirilmiştir.

3.3. İstatistiksel Analiz

Elde edilen verilerin analizinde İstatistik Paket Programı (IBM SPSS 25) kullanılmıştır. Tüm parametreler için analiz öncesinde normal dağılım durumunun değerlendirilmesi öncelikle Kolmogorov-Smirnov testi ile gerçekleştirilmiş; herbir veri için çarpıklık ve basıklık değerlerine bakılmış ve histogram grafik verileri kontrol edilmiştir.

Normallik testine (Kolmogorov-Smirnov) göre $p>0,05$ olanlar normal dağılıma uymaktadır. Ayrıca bu şarta uymayıp çarpıklık ve basıklık değeri (Tabachnick and Fidell, 2013)'e göre -1.5 ile +1.5 arasında olan değerler normal dağılıyor olarak kabul edilmiştir.

Son olarak tanımlayıcı analizler, sürekli değişkenlerde ortalama $\pm$ standart sapma ve kategorik değişkenlerde sayı (yüzde) değeri olarak verilmiştir. Normal dağılım gösteren verilerde, grupların ortalamalarının farklılığının saptanmasında Independent Sample T Testi, normal dağılım göstermeyen verilerde Mann-Whitney U testi kullanılmıştır; Kategorik değişkenlerde ise (Eymen, 2007)'nin belirttiği gibi iki değişken arasındaki ilişkinin istatistiksel olarak anlamlı olup olmadığını belirlemek amacıyla kullanılan, Ki-Kare Bağımsızlık Testi uygulanmıştır. %95 güven aralığında $p<0.05$ değeri istatistiksel olarak anlamlı kabul edilmiştir.

4. BULGULAR

4.1. Veri Setine Ait Bulgular

Makine öğrenmesi sürecinde kullanılan veri setinde normal ve hafif şişman-obez grupların özellikleri hakkında tanımlayıcı istatistikler Tablo 4.1-Tablo 4.7 de sunulmuştur.

Normal ve hafif şişman-obez çocukların cinsiyet, yaş, ailenin gelir durumu, annenin eğitim durumu, annenin mesleği ve babanın mesleği gibi demografik özelliklerine ait bilgiler Tablo 4.1' de gösterilmiştir.

Sistemin kurulumunda kullanılan veri setinde 491 normal ve 294 hafif şişman-obez olmak üzere toplam 785 çocuğun verileri kullanılmıştır. Çocukların %48.4'ü (n=380) erkek ve %51.6'sı (n=405) kızlardan oluşmaktadır. Çocukların %27.4'ü 4 yaşında %36.6'sı 5 yaşında ve %36.1'i 6 yaşındadır. Ailenin gelir durumu incelendiğinde %52.1'inin geliri giderine eşit, %10.3'ünün geliri giderinden az ve %37.6'sının geliri giderinden fazla olduğu görülmüştür. Çocukların annelerinin %14.9'unun lisansüstü, %57.1'inin lisans, %15.7'sinin lise ve %12.4'ünün ilköğretim mezunu olduğu saptanmıştır. Çocukların annelerinin %17.2'sinin sağlık personeli, %35.5'inin devlet memuru, %6.8'inini işçi, esnaf gibi diğer meslek gruplarında olduğu ve %40.5'inin ise ev hanımı olduğu görülmüştür. Babaların %37.6'sının çalışmadığı ve %35'inin ise işçi, esnaf, çiftçi, şoför gibi diğer meslek gruplarında yer aldığı belirlenmiştir. Gruplar arasında demografik özellikler bakımından bir fark saptanmamıştır.

Tablo 4.1. Gruplara Göre Demografik Özelliklerin Dağılımı

		Normal		Hafif şişman -Obez		Toplam		χ^2 ve p
		n	%	n	%	n	%	
Cinsiyet	Erkek	236	48.1	144	49.0	380	48.4	$\chi^2=0.62$ p=0.804
	Kız	255	51.9	150	51.0	405	51.6	
Yaş (yıl)	4	138	28.1	77	26.2	215	27.4	$\chi^2=1.919$ p=0.383
	5	185	37.7	102	34.7	287	36.5	
	6	168	34.2	115	39.1	283	36.1	
Ailenin Gelir Durumu	Geliri Giderine Eşit	249	50.7	160	54.4	409	52.1	$\chi^2=1.015$ p=0.602
	Geliri Giderinden Az	52	10.6	29	9.9	81	10.3	
	Geliri Giderinden Fazla	190	38.7	105	35.7	295	37.6	
Anne Eğitim Durumu	Lisansüstü	83	16.9	34	11.6	117	14.9	$\chi^2=4.970$ p=0.174
	Lisans	279	56.8	169	57.5	448	57.1	
	Lise	72	14.7	51	17.3	123	15.6	
	İlköğretim	57	11.6	40	13.6	97	12.4	
Annenin Mesleği	Sağlık Personeli	93	18.9	42	14.3	135	17.2	$\chi^2=2.926$ p=0.403
	Memur	173	35.3	106	36.1	279	35.5	
	Diğer (İşçi, esnaf)	32	6.5	21	7.1	53	6.8	
	Ev Hanımı	193	39.3	125	42.5	318	40.5	
Babanın Mesleği	Sağlık Personeli	48	9.8	23	7.8	71	9.0	$\chi^2=3.172$ p=0.366
	Memur	97	19.8	50	17.1	147	18.7	
	Diğer (İşçi, esnaf, çiftçi, şoför)	172	35	100	34	272	34.7	
	Çalışmıyor	174	35.4	121	41.1	295	37.6	

Pearson Ki-Kare testi

Gruplara göre vücut ağırlığı, boy uzunluğu ve BKİ değerleri Tablo 4.2.'de sunulmuştur.

Tablo 4.2. Antropometrik Ölçüm Değerlerinin Ortalamaları

	Normal	Hafif Şişman-Obez	Toplam		
	$\bar{X} \pm ss$	$\bar{X} \pm ss$	$\bar{X} \pm ss$	t	p
Vücut Ağırlığı (kg)	18.95 ±3.03	24.12±5.88	20.88±4.99	31.799	0.0001*
Boy Uzunluğu (cm)	112.52±0.85	109.5±1.09	111.3±0.90	4.573	0.0001*
BKİ (kg/m ²)	14.9±1.41	20.2±3.57	16.85±3.53	-15.057	0.0001*

Independent Sample Testi *p<0.05

Çocukların ortalama vücut ağırlıkları 20.88 ± 4.99 kg ve boy uzunlukları 111.3 ± 0.096 cm ve BKİ değerleri 16.85 ± 3.535 kg/m² olduğu saptanmıştır. Gruplara göre değerlendirildiğinde, normal ağırlıktaki grubun ortalama vücut ağırlığı 18.95 ± 3.029 kg ve boy uzunluğu 110 ± 7.76 cm ve BKİ değeri 14.9 ± 1.41 kg/m² olduğu; hafif şişman-obeze grubun ise ortalama vücut ağırlığı 24.12 ± 4.995 kg ve boy uzunluğu 107.5 ± 7.521 cm ve BKİ değeri 20.2 ± 3.57 kg/m² olduğu saptanmıştır. Hafif

şışman-obez çocukların vücut ağırlığı ve BKİ ortalamalarının normal çocuklara göre anlamlı derecede yüksek olduğu boy uzunluklarının ise düşük olduğu görülmüştür ($p<0.05$) (Tablo 4.2).

Grupların çocuğun doğum haftası, doğum ağırlığı, tek başına anne sütü alma süresi, toplam anne sütü alma süresi ve formula mama tüketme durumu gibi yaşamın ilk 1000 gününe ait özelliklerinin dağılımı Tablo 4.3’de verilmiştir.

Tablo 4.3. Gruplara Göre Yaşamın İlk 1000 Gününe Ait Özelliklerin Dağılımı

		Normal		Hafif Şışman-Obez		Toplam		χ^2 ve p
		n	%	n	%	n	%	
Çocuğun Doğum Haftası	37-40 Hafta	398	81.1	220	74.8	618	78.7	$\chi^2=4.322$ p=0.115
	37 Hafta Altı	46	9.4	38	12.9	84	10.7	
	40 Hafta Üstü	47	9.5	36	12.2	83	10.6	
Çocuğun Doğum Ağırlığı (g)	2500-4000	431	87.8	240	81.6	671	85.5	$\chi^2=7.461$ p=0.024*
	<2500	33	6.7	23	7.8	56	7.1	
	>4000	27	5.5	31	10.5	58	7.4	
Çocuğun Tek Başına Anne Sütü Alma süresi	6 Ay	341	69.5	185	62.9	526	67.0	$\chi^2=3.541$ p=0.06
	6 Aydan Az	150	30.5	109	37.1	259	33.0	
Çocuğun Toplam Anne Sütü Alma Süresi	12 Aydan Fazla	363	73.9	210	71.4	573	73.0	$\chi^2=0.584$ p=0.445
	12 Aydan Az	128	26.1	84	28.6	212	27.0	
Çocuğun Formula Tüketme Durumu	Tüketmedi	282	57.4	174	59.2	456	58.1	$\chi^2=0.231$ p=0.631
	Tüketti	209	42.6	120	40.8	329	41.9	

Pearson Ki-Kare testi * $p<0.5$

Çocukların %78.7’sinin 37-40 hafta arasında, %10.7’sinin 37. haftadan önce ve %10.6’sının 40. haftadan sonra doğduğu görülmüştür. Doğum ağırlıkları incelendiğinde %85.5’inin 2500-4000 g arasında, %7.1’inin 2500 g’ın altında ve %7.4’ünün ise 4000 g’ın üstünde doğduğu belirlenmiştir. Çocukların %67’sinin ilk 6 ay tek başına anne sütü aldığı, %33’ünün ise 6 aydan az süre tek başına anne sütü aldığı belirlenmiştir. Toplam anne sütü alma sürelerine bakıldığında; %73’ünün 12 aydan fazla süre ve %27’sinini 12 aydan az süre anne sütü aldığı saptanmıştır. Çocukların %58.1’inin formüle mama tüketmediği ve %41.9’unun ise formüle mama tükettiği görülmüştür. Gruplara göre incelendiğinde; hafif şışman-obez gruptaki çocukların %81.6’sı 2500-4000 g arasında, %7.8’i 2500 g’ın altında, %10.5’i 4000 g’ın üstünde ve normal gruptaki çocukların %87.8’i 2500-4000 g arasında, %6.7’si

2500 g'ın altında % 5.5'i 4000 g'ın üstünde olduğu görülmüştür, Hafif şişman–obez grupta doğum ağırlığı 4000 g üstünde olan çocukların oranının normal gruptaki çocuklara göre anlamlı derecede yüksek olduğu saptanmıştır ($p<0.05$) (Tablo 4.3).

Grupların öğün tüketme sıklıklarına ait özellikleri Tablo 4.4. de sunulmuştur.

Tablo 4.4. Gruplar Arasında Öğün Tüketim Sıklığının Dağılımı

		Normal		Hafif Şişman-Obez		Toplam		χ^2 ve p
		n	%	n	%	n	%	
Kahvaltı	Her gün	453	92.3	284	96.6	737	93.9	$\chi^2= 5.296$ $p=0.021^*$
	Arada bir	38	7.7	10	3.4	48	6.1	
Öğle	Her gün	343	69.9	182	61.9	525	66.9	$\chi^2=6.049$ $p=0,051$
	Arada bir	139	28.3	102	34.7	241	30.7	
	Hiç	9	1.8	10	3.4	19	2.4	
Akşam	Her gün	459	93.5	286	97.3	745	94.9	$\chi^2=4.723$ $p=0.030^*$
	Arada bir	32	6.5	8	2,7	40	5.1	
Kuşluk	Her gün	78	15.9	42	15.9	120	15.3	$\chi^2=1.391$ $p=0.499$
	Arada bir	215	43.8	121	59.7	336	42.8	
	Hiç	198	40.3	131	100	329	41.9	
İkinci	Her gün	122	24.8	67	22.8	189	24.1	$\chi^2=1.736$ $p=0.420$
	Arada bir	282	57.4	164	55.8	446	56.8	
	Hiç	87	17.7	63	21.4	150	19.1	
Yatsı	Her gün	172	35.0	111	37.8	283	36.1	$\chi^2=1.883$ $p=0.390$
	Arada bir	248	50.5	134	45.6	382	48.7	
	Hiç	71	14.5	49	16.7	120	15.3	

Pearson Ki-Kare testi * $p<0.05$

Çocukların öğün tüketim sıklıkları incelendiğinde; sabah öğününü %93.9'unun her gün ve %6.1'inin arada bir tükettiği, öğle öğününü %66.9'unun her gün, %30.7'sinin arada bir tükettiği ve %2.4'ünün ise hiç tüketmediği, akşam öğününü %94.9'unun her gün ve %5.1'inin ise arada bir tükettiği, kuşluk öğününü %15.1'inin her gün, %42.8'inin arada bir tükettiği ve %41.9'unun hiç tüketmediği, ikinci ara öğününü ise %24.1'inin her gün, %56.8'inin arada bir tükettiği ve %19.1'inin hiç tüketmediği, yatsı ara öğününü %36.1'inin her gün, % 48.7'sinin arada bir tükettiği ve %15.3'ünün hiç tüketmediği saptanmıştır. Gruplara göre incelendiğinde hafif şişman-obez çocukların kahvaltı ve akşam öğününü her gün tüketim durumlarının normal gruba göre anlamlı derecede yüksek olduğu saptanmıştır. Diğer öğünlerde gruplar arasında bir fark saptanmamıştır ($p<0.05$) (Tablo 4.4).

Çocukların gruplara göre bazı besinleri tüketim sıklıkları Tablo 4.5 de gösterilmiştir.

Tablo 4.5. Bazı Besinlerin Tüketim Sıklığının Gruplar Arasındaki Dağılımı

		Normal		Hafif Şişman- Obez		Toplam		χ^2 ve p
		n	%	n	%	n	%	
Süt ve ürünleri	Her gün	382	77.8	233	79.3	615	78.3	$\chi^2=0.228$ p=0.633
	Arada bir	109	22.2	61	20.7	170	21.7	
Et ve Ürünleri	Her gün	149	30.3	120	40.8	269	34.3	$\chi^2=8.949$ p=0.03*
	Arada bir	342	69.7	174	59.2	516	65.7	
	Toplam	491	100	294	100	785	100	
Tahıl ve Tahıl Ürünleri	Arada bir	240	48.9	144	49.0	384	48.9	$\chi^2=0.136$ p=0.934
	Hiç	42	8.6	23	7.8	65	8.3	
	Her gün	209	42.6	127	43.2	336	42.8	
Meyve ve Sebze	Her gün	404	82.3	233	79.3	637	81.1	$\chi^2=1.103$ p=0.294
	Arada bir	87	17.7	61	20.7	148	18.9	
	Toplam	491	100	294	100	785	100	
Bal, reçel, pekmez vb.	Hiç	58	11.8	33	11.2	91	11.6	$\chi^2=0.134$ p=0.935
	Arada bir	276	56.2	169	57.5	445	56.7	
	Her gün	157	32.0	92	31.3	249	31.7	
Tereyağı	Hiç	79	16.1	42	14.3	121	15.4	$\chi^2=1.505$ p=0.471
	Arada bir	272	55.4	176	59.9	448	57.1	
	Her gün	140	28.5	76	25.9	216	27.5	
Fast-food	Hiç	99	20.2	62	21.1	161	20.5	$\chi^2=0.135$ p=0.935
	Arada bir	378	77.0	223	75.9	601	76.6	
	Her gün	14	2.9	9	3.1	23	2.9	
Hamur işi	Arada bir	448	91.2	276	93.9	724	92.2	$\chi^2=1.871$ p=0.392
	Her gün	43	8.8	18	6.1	61	7.8	
Cips/kızartma vb.	Hiç	40	8.1	18	6.1	58	7.4	$\chi^2=1.101$ p=0.577
	Arada bir	415	84.5	254	86.4	669	85.2	
	Her gün	36	7.3	22	7.5	58	7.4	
Gazlı/şekerli İçecekler	Hiç	175	35.6	92	31.3	267	34.0	$\chi^2=4.389$ p=0.111
	Arada bir	296	60.3	181	61.6	477	60.8	
	Her gün	20	4.1	21	7.1	41	5.2	
Çikolata, Bisküvi, Kraker vb.	Hiç	11	2.2	6	2.0	17	2.2	$\chi^2=1.103$ p=0.576
	Arada bir	350	71.3	200	68.0	550	70.1	
	Her gün	130	26.5	88	29.9	218	27.8	

Pearson Ki-Kare testi *p<0.05

Çocukların süt ve ürünlerini %78.3'ünün her gün ve %21.7'sinin arada bir tükettiği, et ve ürünlerini %34.3'ünün her gün ve % 65.7'sinin arada bir tükettiği görülmüştür. Tahıl ve ürünlerinin tüketim sıklığına bakıldığında ise %42.3'ünün her gün, %48.9'unun arada bir tükettiği ve %8.3'ünün ise hiç tüketmediği görülmüştür. Meyve ve sebze grubundaki besinlere bakıldığında çocukların %81'inin her gün %18.9'unun arada bir tükettiği saptanmıştır. Bal, reçel, pekmez gibi şekerli besinleri çocukların %11.6'sının hiç tüketmediği, %56.7'sinin arada bir ve % 31.7'sinin ise her gün tükettiği görülmüştür. Tereyağı %15.4'ünün hiç tüketmediği, %57.1'inin arada bir ve %27.5'inin her gün tükettiği görülmüştür. Fast food tarzı yüksek yağ ve

enerji içeren besinleri ise %20.5'inin hiç tüketmediği, %76.6'sının arada bir ve %2.9'unun hiç tüketmediği belirlenmiştir. Hamur işini %1.1'inin hiç tüketmediği, %91.1'inin arada bir ve %7.8'inin her gün tükettiği görülmüştür. Cips, kızartma vb. gibi yüksek yağ ve enerji içeren besinleri ise %7.4'ünün hiç tüketmediği, %85.2'sinin arada bir ve %7.4'ünün her gün tükettiği saptanmıştır. Gazlı ve şekerli içecekleri çocukların %34 ünün hiç tüketmediği, %60.8'inini arada bir tükettiği ve %5.2'sinin her gün tükettiği belirlenmiştir. Çikolata, bisküvi, kraker vb. gibi paketli ve işlenmiş yüksek yağ, karbonhidrat ve enerji içeren besinleri ise %2.2'sinin hiç tüketmediği, %70.1'inin arada bir ve %27.8'inin her gün tükettiği görülmüştür. Gruplara göre bakıldığında hafif şişman-obez gruptaki çocukların et ve ürünlerini her gün tüketim durumlarının normal gruptaki çocuklara göre anlamlı derecede yüksek olduğu görülmüştür ($p<0.05$). Diğer besinlerde gruplar arasında bir fark saptanmamıştır (Tablo 4.5).

Çocukların gruplara göre travmatik bir olay yaşama durumları ve ailelerinde obezite varlığına ait özelliklerin dağılımı Tablo 4.6'da gösterilmiştir.

Tablo 4.6. Gruplara Göre Psikolojik ve Genetik Faktörlerin Dağılımı

		Normal		Hafif Şişman - Obez		Toplam		χ^2 ve p
		n	%	n	%	n	%	
Çocuğun Travmatik Olay Yaşama Durumu	Hayır	408	83.1	246	83.7	654	83.3	$\chi^2=0.044$ $p=0.834$
	Evet	83	16.9	48	16.3	131	16.7	
	Toplam	491	100	294	100	785	100	
Ailede Obezite Varlığı	Hayır	366	74.5	189	64.3	555	70.7	$\chi^2=9.338$ $p=0.002^*$
	Evet	125	25.5	105	35.7	230	29.3	
	Toplam	491	100	294	100	785	100	

*Pearson Ki-Kare testi * $p<0.05$*

Çocukların %83.3'ünün hiç travmatik bir olay yaşamadığı %16,7'sinin ise en az bir kez travmatik bir olay yaşadıkları saptanmıştır. Gruplar arasında bir fark saptanmamıştır (Tablo 4.6).

Ailede obezite varlığına bakıldığında %70.7'sinin ailesinde obez birey olmadığı ancak %29.3'ünün ailesinden az bir obez birey olduğu görülmüştür (Tablo 4.6). Gruplara göre bakıldığında ise normal gruptaki çocukların %25.5'inin, hafif şişman-obez gruptakilerin ise %35.7'sinin ailelerinde obez birey olduğu görülmüştür ($p<0.05$) (Tablo 4.6).

Grupların gün içerisindeki fiziksel aktivite süresi, bilgisayar, tablet, cep telefonu ve televizyon başında geçirdikleri süre gibi enerji harcamaları ile ilişkili özelliklerin dağılımı Tablo 4.7 de gösterilmiştir.

Gün içerisinde toplam aktivite süreleri incelendiğinde çocukların %31.6 sinin 2 saat üstü, %33.2 sinin 1-2 saat ve %35.2 sinin 1 saatin altında aktivite yaptıkları görülmüştür. Bilgisayar, tablet, telefon gibi cihazlarla internet başında ders dışı geçirilen süreler bakıldığında %40.3 ünün 1 saatin altında, %24.6 sinin 1-2 saat ve %35.2 sinin 2 saat üstünde zaman geçirdiği; televizyon başında geçirilen süreler bakıldığında ise %55 inin 1 saatin altında, %28 inin 1-2 saat ve %16.9 unun 2 saatin üstünde zaman geçirdikleri saptanmıştır. Gün içerisindeki aktivite süresi, televizyon ve bilgisayar, tablet, cep telefonu karşısında geçirilen süreler bakımından gruplar arasında bir fark bulunamamıştır (Tablo 4.7).

Tablo 4.7. Gruplara Göre Gün İçerisindeki Aktivite ve Ekran Sürelerinin Dağılımı

		Normal		Hafif Şişman- Obez		Toplam		χ^2 ve p
		n	%	n	%	n	%	
Aktivite Süresi (saat)	$2 \geq$	161	32.8	87	29.6	248	31.6	$\chi^2=5.159$ p=0.076
	1-2	172	35.0	89	30.3	261	33.2	
	≤ 1	158	32.2	118	40.1	276	35.2	
Bilgisayar/ Tablet/ Telefon Başında Geçirdiği Süre	≤ 1	185	37.7	131	44.6	316	40.3	$\chi^2=3.785$ p=0.151
	1-2	128	26.1	65	22.1	193	24.5	
	$2 \geq$	178	36.3	98	33.3	276	35.2	
Televizyon Başında Geçirdiği Süre	≤ 1	280	57.0	152	51.7	432	55.1	$\chi^2=5.004$ p=0.082
	1-2	139	28.3	81	27.6	220	28.0	
	$2 \geq$	72	14.7	61	20.7	133	16.9	


Pearson Ki-Kare testi *p<0.05

4.2. WEKA Uygulamasına Ait Bulgular


Veri seti “csv.” formatına dönüştürülerek WEKA programına yüklenmiş ve ön işlem aşaması gerçekleştirilmiştir. Ardından makine öğrenmesi algoritmaları ile modeller kurulmuş ve modellerin performansları; doğruluk oranı, duyarlılık, hassasiyet, F-ölçütü, kappa istatistiği, MCC değeri ve karmaşıklık matrisi değerleri saptanmıştır.

4.2.1. WEKA Ön İşlem (Preprocess) Sekmesi Sonuçları

WEKA’da veri setinde kullanılan özniteliklerin dağılımı Şekil 4.1. ve Şekil 4.2.’de gösterilmiştir. Her bölüm, üzerinde belirtilen öz niteliği temsil etmektedir. Mavi boyalı alanlar o grup içerisindeki normal gruptaki çocukları, kırmızı boyalı olanlar ise hafif şişman-obez gruptaki çocukları temsil etmektedir.



Şekil 4.1. Veri Setinin Özniteliklerinin Gruplara Göre Dağılımı 1



Şekil 4.2. Veri Setinin Özniteliklerinin Gruplara Göre Dağılımı 2

4.2.2. Makine Öğrenmesi Algoritmaları ile Kurulan Modellere ait Bulgular

Yapılan çalışmada, WEKA programında Naive Bayes, IBk (k-en yakın komşu), multilayer perception (yapay sinir ağı-YSA), J48 (karar ağacı), Logistic (lojistik regresyon) ve LibSVM (destek vektör makinesi) algoritmaları ile modeller kurulmuştur.

Naive Bayes Modeli Bulguları

Naive Bayes modeli performans ölçüt sonuçları Şekil 4.3'te ve Tablo 4.8'de verilmiştir.

```
=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances      591              75.2866 %
Kappa statistic                    0.4404
Mean absolute error                 0.3036
Root mean squared error             0.416
Relative absolute error              64.7924 %
Root relative squared error         85.9529 %
Total Number of Instances          785

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall   F-Measure  MCC      ROC Area  PRC Area  Class
                0,888    0,473    0,758      0,888    0,818      0,454    0,794    0,833     0
                0,527    0,112    0,738      0,527    0,615      0,454    0,794    0,747     1
Weighted Avg.   0,753    0,338    0,751      0,753    0,742      0,454    0,794    0,801

=== Confusion Matrix ===

  a  b  <-- classified as
436 55 |  a = 0
139 155 | b = 1
```

Şekil 4.3. Naive Bayes Modeli Performans Ölçüt Sonuçları

Tablo 4.8. Naive Bayes Algoritması Karmaşıklık Matrisi

		Tahmin	
		Normal	Hafif Şişman-Obez
Gerçek	Normal	436 (TP)	55 (FN)
	Hafif Şişman-Obez	139 (FP)	155 (TN)

Naive Bayes modeli %75.2866 doğruluk oranı ile verileri sınıflandırmıştır. NB modelinin duyarlılık oranının 0.888, hassaslık oranının 0.758, F ölçütünün 0.818 ve Kappa istatistiğinin 0.4404 ve MCC değerinin 0.454 olduğu saptanmıştır. NB

algoritması 491 normal vücut ağırlığındaki çocuğun 436 tanesini doğru tahmin etmiş, 55 tanesini yanlış tahmin etmiştir ve 294 hafif şişman-obez çocuktan ise 155 tanesini doğru, 139 tanesini ise yanlış tahmin etmiştir. NB algoritması ile kurulan model ile 785 verinin toplam 591 adeti doğru sınıflandırılmıştır.

IBk Modeli Bulguları

IBk modelinin performans ölçüt sonuçları Şekil 4.4'te ve Tablo 4.9'da gösterilmiştir.

```

=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances      476           60.6369 %
Kappa statistic                    0.1332
Mean absolute error                 0.3939
Root mean squared error             0.6265
Relative absolute error             84.0648 %
Root relative squared error         129.4497 %
Total Number of Instances          785

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall   F-Measure  MCC      ROC Area  PRC Area  Class
                0,731   0,602   0,670     0,731   0,699     0,134   0,569    0,670     0
                0,398   0,269   0,470     0,398   0,431     0,134   0,569    0,417     1
Weighted Avg.   0,606   0,477   0,595     0,606   0,599     0,134   0,569    0,575

=== Confusion Matrix ===

  a  b  <-- classified as
359 132 |  a = 0
177 117 |  b = 1

```

Şekil 4.4. IBk (k-en yakın komşu) Modeli Performans Ölçüt Sonuçları

Tablo 4.9. IBk (k-en yakın komşu) Algoritması Karmaşıklık Matrisi

		Tahmin	
		Normal	Hafif Şişman-Obez
Gerçek	Normal	359 (TP)	132 (FN)
	Hafif Şişman-Obez	177 (FP)	117 (TN)

IBk (k-en Yakın Komşu- kNN) modeli %60.6369 doğruluk oranı ile verileri sınıflandırmıştır. IBk modelinin duyarlılık oranının 0.731, hassaslık oranının 0.670, F-ölçütünün 0.699, MCC değerinin 0.134 ve kappa istatistiğinin 0.1332 olduğu saptanmıştır. IBk algoritması 491 normal vücut ağırlığındaki çocuğun 359 tanesini doğru tahmin etmiş, 132 tanesini yanlış tahmin etmiştir ve 294 hafif şişman-obez

çocuktan 117 tanesini doğru, 177 tanesini ise yanlış tahmin etmiştir. IBk algoritması ile kurulan model 785 verinin 476 tanesini doğru sınıflandırmıştır.

Multilayer Perception Modeli Bulguları

Multilayer Perception algoritması performans ölçüt sonuçları Şekil 4.5'te ve Tablo 4.10'da gösterilmektedir.

```

=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances      685           87.2611 %
Kappa statistic                    0.7247
Mean absolute error                 0.1382
Root mean squared error             0.3152
Relative absolute error             29.4895 %
Root relative squared error         65.1256 %
Total Number of Instances          785

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall   F-Measure  MCC      ROC Area  PRC Area  Class
                0,916   0,201   0,884     0,916   0,900     0,726   0,945   0,964    0
                0,799   0,084   0,851     0,799   0,825     0,726   0,945   0,920    1
Weighted Avg.   0,873   0,157   0,872     0,873   0,872     0,726   0,945   0,948

=== Confusion Matrix ===

  a  b  <-- classified as
450 41 |  a = 0
 59 235 | b = 1

```

Şekil 4.5. Multilayer Perception (YSA) Modeli Performans Ölçüt Sonuçları

Tablo 4.10. Yapay Sinir Ağı Algoritması Karmaşıklık Matrisi

		Tahmin	
		Normal	Hafif Şişman-Obez
Gerçek	Normal	450 (TP)	41 (FN)
	Hafif Şişman-Obez	59 (FP)	235 (TN)

Multilayer Perception (Yapay Sinir Ağı-YSA) modeli %87.2611 doğruluk oranı ile verileri sınıflandırmıştır. YSA modelinin duyarlılık oranının 0.916, hassaslık oranının 0.884, F ölçütünün 0.900, MCC değerinin 0.726 ve kappa istatistiğinin 0.7247 olduğu saptanmıştır. YSA algoritması 491 normal vücut ağırlığındaki çocukların 450 tanesini doğru tahmin etmiş, 41 tanesini yanlış tahmin etmiştir ve 294 hafif şişman-obez çocuktan 235 tanesini doğru, 59 tanesini ise yanlış tahmin etmiştir. YSA algoritması ile kurulan model 785 verinin 685 tanesini doğru sınıflandırmıştır.

J48 Modeli Bulguları

J48 modeli performans ölçüt sonuçları Şekil 4.6.'da ve Tablo 4.11.'de gösterilmiştir.

```
=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances      739           94.1401 %
Kappa statistic                    0.8756
Mean absolute error                 0.0796
Root mean squared error             0.2393
Relative absolute error             16.9845 %
Root relative squared error         49.432 %
Total Number of Instances          785

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall   F-Measure  MCC      ROC Area  PRC Area  Class
                0,945    0,065    0,961     0,945    0,953      0,876    0,935    0,948     0
                0,935    0,055    0,911     0,935    0,923      0,876    0,935    0,839     1
Weighted Avg.   0,941    0,061    0,942     0,941    0,942      0,876    0,935    0,907

=== Confusion Matrix ===

  a    b  <-- classified as
464  27 |   a = 0
 19 275 |   b = 1
```

Şekil 4.6. J48 (Karar Ağacı) Modeli Performans Ölçüt Sonuçları

Tablo 4.11. J48 (Karar Ağacı) Algoritması Karmaşıklık Matrisi

		Tahmin	
		Normal	Hafif Şişman-Obez
Gerçek	Normal	464 (TP)	27 (FN)
	Hafif Şişman-Obez	19 (FP)	275 (TN)

J48 Karar Ağacı modeli %94.1401 doğruluk oranı ile verileri sınıflandırmıştır. J48 Modelinin duyarlılık oranının 0.945, hassaslık oranının 0.961, F-ölçütünün 0.953, MCC değerinin 0.876 ve kappa istatistiğinin 0.8756 olduğu saptanmıştır. J48 algoritması 491 normal gruptaki çocukların 464 tanesini doğru tahmin etmiş, 27 tanesini yanlış tahmin etmiştir ve 294 hafif şişman-obez çocuktan 275 doğru, 19 tanesini ise yanlış tahmin etmiştir. J48 algoritması ile kurulan model 785 verinin 739 tanesini doğru sınıflandırmıştır.

Lojistik Regresyon Modeli Bulguları

Lojistik regresyon modeli performans ölçüt sonuçları Şekil 4.7.'de ve Tablo 4.12.'de gösterilmiştir.

```

=== Summary ===

Correctly Classified Instances      657          83.6943 %
Kappa statistic                    0.6539
Mean absolute error                 0.1954
Root mean squared error             0.3483
Relative absolute error              41.6991 %
Root relative squared error          71.9536 %
Total Number of Instances          785

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall   F-Measure  MCC      ROC Area  PRC Area  Class
                0,862   0,204   0,876     0,862   0,869     0,654   0,912    0,943    0
                0,796   0,138   0,775     0,796   0,785     0,654   0,912    0,879    1
Weighted Avg.   0,837   0,180   0,838     0,837   0,837     0,654   0,912    0,919

=== Confusion Matrix ===

  a    b  <-- classified as
423  68 |   a = 0
 60 234 |   b = 1

```

Şekil 4.7. Logistic (Lojistik Regresyon) Modeli Performans Ölçüt Sonuçları

Tablo 4.12. Lojistik Regresyon Algoritması Karmaşıklık Matrisi

		Tahmin	
		Normal	Hafif Şişman-Obez
Gerçek	Normal	423 (TP)	68 (FN)
	Hafif Şişman-Obez	60 (FP)	234 (TN)

Lojistik regresyon modeli %83.6943 doğruluk oranı ile verileri sınıflandırmıştır. Lojistik regresyon modelinin duyarlılık oranının 0.862, hassaslık oranının 0.876, F-ölçütünün 0.869, MCC değerinin 0.654 ve kappa istatistiğinin 0.6539 olduğu saptanmıştır. Lojistik regresyon algoritması 491 normal gruptaki çocukların 423 tanesini doğru tahmin etmiş, 68 tanesini yanlış tahmin etmiştir ve 294 hafif şişman-obez çocuktan 234 doğru, 60 tanesini ise yanlış tahmin etmiştir. Lojistik regresyon algoritması ile kurulan model 785 verinin 657 tanesini doğru sınıflandırmıştır.

Destek Vektör Makinesi Modeli Bulguları

DVM modeli performans ölçüt sonuçları Şekil 4.8.'de ve Tablo 4.13.'de gösterilmiştir.

```

=== Summary ===

Correctly Classified Instances      616              78.4713 %
Kappa statistic                    0.5108
Mean absolute error                0.2153
Root mean squared error            0.464
Relative absolute error             45.9422 %
Root relative squared error         95.8648 %
Total Number of Instances          785

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall   F-Measure  MCC      ROC Area  PRC Area  Class
                0,919   0,439   0,778     0,919   0,842     0,529   0,740    0,765     0
                0,561   0,081   0,805     0,561   0,661     0,529   0,740    0,616     1
Weighted Avg.   0,785   0,305   0,788     0,785   0,774     0,529   0,740    0,709

=== Confusion Matrix ===

  a  b  <-- classified as
451 40 |  a = 0
129 165 | b = 1

```

Şekil 4.8. Destek Vektör Makinesi (LibSVM) Modeli Performans Ölçüt Sonuçları

Tablo 4.13. Destek Vektör Makinesi (LibSVM) Algoritması Karmaşıklık Matrisi

		Tahmin	
		Normal	Hafif Şişman-Obez
Gerçek	Normal	451 (TP)	40 (FN)
	Hafif Şişman-Obez	129 (FP)	165 (FN)

Destek vektör makinesi modeli %78.4713 doğruluk oranı ile verileri sınıflandırmıştır. LibSVM modelinin duyarlılık oranının 0.919, hassaslık oranının 0.778, F-ölçütünün 0.842, MCC değerinin 0.529 ve kappa istatistiğinin 0.5108 olduğu saptanmıştır. DVM algoritması 491 normal gruptaki çocukların 451 tanesini doğru tahmin etmiş, 40 tanesini yanlış tahmin etmiştir ve 294 hafif şişman-obez çocuktan 165 doğru, 129 tanesini ise yanlış tahmin etmiştir. LibSVM algoritması ile kurulan model 785 verinin 616 tanesini doğru sınıflandırmıştır.

4.2.3. Geliştirilen Modellerin Performans Ölçütlerinin Karşılaştırılması

Çalışmamızda çocukluk çağı obezite riski için tahmin işlemi gerçekleştirecek sistemin kurulması için beş makine öğrenmesi algoritması ile beş farklı model kurulmuştur. Geliştirilen modellere ait performans ölçüt sonuçları Tablo 4.14'te sunulmuştur.

Tablo 4.14. Makine Öğrenmesi Algoritmalarının Sınıflandırma Performans Ölçütleri

	NB	IBk	YSA	J48	Logistic	LibSVM
Doğruluk Oranı (%)	75.28	60.63	87.26	94.14	83.69	78.47
Duyarlılık	0.888	0.731	0.916	0.945	0.862	0.919
Hassasiyet	0.758	0.670	0.884	0.961	0.876	0.778
F-ölçütü	0.818	0.699	0.900	0.953	0.869	0.842
MCC	0.454	0.134	0.726	0.876	0.654	0.529
Kappa İstatistiği	0.4404	0.1332	0.7247	0.8756	0.6539	0.5108
TP	436	359	450	464	423	451
FP	139	177	59	19	60	129
FN	55	132	41	27	68	40
TN	155	117	235	275	234	165

Kurulan modelin performansının değerlendirilmesinde en yaygın kullanılan metrik modelin doğruluk değeridir. Doğru sınıflandırılan veri sayısının toplam veriye oranı olan doğruluk değeri incelendiğinde en düşük doğruluğu %60.636 ile IBk modeli gösterirken, en yüksek doğruluğu %94.14 ile J48 modeli göstermiştir. Özellikle eşit dağılmayan veri kümelerinde model doğruluğu tek başına yeterli değildir. Bu nedenle diğer metriklerin sonuçlarını da birlikte değerlendirmek gereklidir. Duyarlılık değerlerine bakıldığında normal gruptaki çocukları en yüksek oranda normal olarak sınıflandıranın J48 algoritması olduğu, hassasiyet değerlerine bakıldığında tüm verileri en yüksek oranda doğru olarak tahmin eden algoritmanın J48 olduğu, hassasiyet ve duyarlılık değerlerinin harmonik ortalaması olan F-ölçütü, gerçek değerler ile tahmin verileri arasındaki korelasyon ilişkisini gösteren MCC değerleri ve tahmin edilen değerler ile gerçek değerlerin uyumunun güvenilirliğini gösteren kappa istatistik değerleri incelendiğinde en yüksek değerin J48 algoritmasına ait olduğu görülmüştür. J 48 algoritmasının doğruluk oranı, hassasiyet, F-ölçütü ve kappa istatistik değerleri diğer algoritmalarından daha yüksek bulunmuştur (Tablo


4.14). Bu sebeple sistemin kurulmasında J 48 karar ağacı modelinin kullanılmasına karar verilmiştir.

4.3. J 48 Modeli ile Kurulan Sisteme ait Bulgular

4.3.1. Sistemim Tahmin Sonuçları ile Öznitelikler Arasındaki İlişki

Çalışmamızda geliştirilen karar ağacı algoritması ile çocukluk çağı obezite riskini saptayan web tabanlı erken uyarı sistemini test etmek amacı ile sistemin geliştirilmesinde verileri kullanılmamış 100 çocuğun aileleri ile yüz yüze görüşülerek çocuklarının obezite riskleri sistem tarafından tahmin edilmiştir. Ailelerin verdikleri cevaplar kaydedilmiştir.

Obezite riski sistem tarafından tahmin edilen çocukların %45'i erkek, %55'i kız çocuklardan oluşmaktadır (Şekil 4.9). Çocukların %24'ü 4 yaşında %36'sı 5 yaşında ve %40'ı 6 yaşındadır (Şekil 4.10). Sistemin 56 çocuğun obezite riskini “düşük” olarak tahmin ettiği ve 44 çocuğun obezite riskini “yüksek” olarak tahmin ettiği görülmüştür (Tablo 4.15).




Şekil 4.9. Gruplara Göre Cinsiyet Dağılımı

Tablo 4.15. Demografik Özellikler in Sistem Tahmin Sonuçlarına Göre Dağılımı

		Obezite Riski Düşük (n=56)		Obezite Riski Yüksek (n=44)		Toplam (n=100)		χ^2 ve p
		n	%	n	%	n	%	
Cinsiyet	Erkek	24	42.9	21	47.7	45	45	$\chi^2=0.236$ p=0.627
	Kız	32	57.1	23	52.3	55	55	
Yaş	4	16	28.6	8	18.2	24	24	$\chi^2=1.696$ p=0.428
	5	20	35.7	16	36.4	36	36	
	6	20	35.7	20	45.5	40	40	
Ailenin Gelir Durumu	Gelir giderine eşit	29	51.8	24	54.5	53	53	$\chi^2=2.264$ p=0.322
	Gelir giderinden az	9	16.1	11	25.0	20	20	
	Gelir giderinden fazla	18	32.1	9	20.5	27	27	
Anne Eğitim Durumu	Lisans/lisansüstü	40	71.4	24	54.5	64	64	$\chi^2=3.105$ p=0.212
	Lise	11	19.6	13	29.5	24	24	
	İlköğretim	5	8.9	7	15.9	12	12	
Annenin Mesleği	Sağlık çalışanı	8	14.3	4	9.1	12	12	$\chi^2=6.311$ p=0.097
	Memur	13	23.2	3	6.8	16	16	
	Diğer	8	14.3	9	20.5	17	17	
	Ev hanımı	27	48.2	28	63.6	55	55	
Babanın Mesleği	Sağlık Çalışanı	7	12.5	4	9.1	11	11	$\chi^2=10.532$ p=0.005*
	Memur	26	46.4	8	18.2	34	34	
	Diğer	23	41.1	32	72.7	55	55	

Pearson Ki-Kare testi *p<0.05

**Şekil 4.10.** Gruplara Göre Yaş Dağılımı


Sistem tarafından obezite riski yüksek tahmin edilen çocuklar ile obezite riski düşük tahmin edilen çocuklar arasında cinsiyet, yaş, gelir durumu, annenin eğitim durumu ve annenin mesleği açısından istatistiksel olarak anlamlı bir fark görülmemiştir ($p>0.05$). Ancak istatistiksel olarak anlamlı olmasa da obezite riski yüksek tahmin

edilen çocukların annelerinin sağlık çalışanı ve memura göre daha çok diğer meslek gruplarından veya ev hanımı oldukları görülmektedir. Ayrıca obezite riski düşük çocukların babalarının sağlık çalışanı ve memur olma durumunun obezite riski yüksek çıkan çocuklara göre anlamlı derecede yüksek olduğu görülmüştür. Obezite riski yüksek çocukların babalarının meslekleri ise daha çok serbest meslek mensubu, esnaf, işsiz vb. olduğu görülmüştür ($p<0.05$) (Tablo 4.15).

Tablo 4.16. Sistem Tahmin Sonuçlarına Göre Antropometrik Ölçümlerin Ortalaması

	Obezite Riski Düşük (n=56)	Obezite Riski Yüksek (n=44)	Toplam (n=100)		
	$\bar{X} \pm ss$	$\bar{X} \pm ss$	$\bar{X} \pm ss$	t	p
Vücut Ağırlığı	18.11 $\pm$ 2.91	20.93 $\pm$ 3.81	19.35 $\pm$ 3.61	-4.204	0.0001*
Boy Uzunluğu	110.48 $\pm$ 7.76	108.75 $\pm$ 7.52	109.3 $\pm$ 7.66	-1.135	0.259
BKİ	14.76 $\pm$ 1.46	17.69 $\pm$ 2.3	16.05 $\pm$ 2.37	-7.369	0.0001*

Independent Sample * $p<0.05$



Şekil 4.11. Gruplara Göre Antropometrik Ölçüm Değerlerinin Dağılımı

Çocukların vücut ağırlığı ve boy uzunlukları ölçülmüş ve BKİ değerleri hesaplanmıştır. Çocukların ortalama BKİ değerleri 16.05 $\pm$ 2.37 kg/m^2 dir. Sistem tarafından obezite riski düşük olarak tahmin edilen çocukların (n=56) ortalama BKİ değerleri 14.76 $\pm$ 1.46 kg/m^2 ve obezite riski yüksek olarak tahmin edilen çocukların

(n=44) ortalama BKİ değerleri $17.69 \pm 2.3 \text{ kg/m}^2$ dir. Çocukların vücut ağırlıkları ve BKİ ortalamalarının obezite riski yüksek olan grupta obezite riski düşük olan gruba göre anlamlı derecede yüksek olduğu saptanmıştır ($p < 0.05$) Boy uzunluklarında ise gruplar arasında bir fark bulunmamıştır (Tablo 4.16, Şekil 4.11).

Tablo 4.17. Sistem Tahmin Sonuçlarına göre BKİ Gruplarının Dağılımı

	Obezite Riski Düşük		Obezite Riski Yüksek		Toplam	χ^2 ve p
	n	%	n	%		
Zayıf	10	17.9	1	2.3	11	$\chi^2=24.573$ $p=0.0001^*$
Normal	44	78.6	26	59.1	70	
Hafif Şişman	2	3.6	4	9.1	6	
Obez	0	0	13	29.5	13	
Toplam	56	100	44	100	100	

*Pearson Ki-Kare testi * $p < 0.05$*

Sistem tarafından obezite riski düşük olarak tahmin edilen çocukların %17.9'unun zayıf, %78.6'sının normal, %3,6'sının hafif şişman olduğu görülmüştür. Obez çocukların ise hiç birinin obezite riskini düşük olarak tahmin etmediği görülmüştür (Tablo 4.18). Obezite riski yüksek olarak tahmin edilen çocukların ise %2.3'ünün zayıf, %59.1'inin normal %9.1'inin hafif şişman %29.5'inin obez olduğu görülmüştür ($p < 0.05$) (Tablo 4.18).

Tablo 4.18. Sistem Tahmin Sonuçlarına Göre Yaşamın İlk 1000 Gününe ait Özelliklerin Dağılımı

		Obezite Riski Düşük (n=56)		Obezite Riski Yüksek (n=44)		Toplam (n=100)		χ^2 ve p
		n	%	n	%	n	%	
Çocuğun Doğum Haftası	37-40	42	75.0	29	65.9	71	71	$\chi^2=1.326$ $p=0.515$
	< 37	3	5.4	2	4.5	5	5	
	>40	11	19.6	13	29.5	24	24	
Doğum Ağırlığı (g)	2500-4000	46	82.1	38	86.4	84	84	$\chi^2=0.394$ $p=0.821$
	< 2500	6	10.7	4	9.1	10	10	
	> 4000	4	7.1	2	4.5	6	6	
Tek Başına Anne Sütü Alma süresi	6 ay	49	87.5	35	79.5	84	84	$\chi^2=1.160$ $p=0.281$
	< 6 ay	7	12.5	9	20.5	16	16	
Toplam anne Sütü Alma Süresi	< 12 ay	43	76.8	29	65.9	72	72	$\chi^2=1.446$ $p=0.164$
	> 12 ay	13	23.2	15	34.1	28	28	
Formula Tüketme Durumu	Hayır	38	67.9	23	52.3	61	61	$\chi^2=1.903$ $p=0.168$
	Evet	18	32.1	21	47.7	39	39	

*Pearson Ki-Kare testi * $p < 0.05$*

Sistem tarafından obezite riski yüksek ve obezite riski düşük tahmin ettiği çocukların doğum ağırlıkları, doğum haftası, sadece anne sütü alma süresi, toplam anne sütü alma süresi ve formüle tüketme durumu gibi yaşamın ilk 1000 gününe ait özellikleri açısından istatistiksel olarak bir fark görülmemiştir ($p>0.05$) (Tablo 4.18)

Sistemin obezite riskini yüksek olarak tahmin ettiği çocukların düşük riskli tahmin edilen çocuklara göre kahvaltı öğününü daha sık atladıkları görülmüştür ($p<0.05$) Diğer öğünler için gruplar arasında bir fark bulunamamıştır (Tablo 4.19).

Tablo 4.19. Sistem Tahmin Sonuçlarına Göre Öğün Tüketim Sıklıklarının Dağılımı

		Obezite Riski Düşük (n=56)		Obezite Riski Yüksek (n=44)		Toplam (n=100)		χ^2 ve p
		n	%	n	%	n	%	
Kahvaltı	Her Gün	54	96.4	36	81.8	90	90	$\chi^2=7.468$ $p=0.024^*$
	Arada Bir	2	3.6	3	6.8	5	5	
	Hiç	0	0.0	5	11.4	5	5	
Öğle	Her Gün	37	66.1	29	65.9	66	66	$\chi^2=3.063$ $p=0.216$
	Arada Bir	18	32.1	11	25.0	29	29	
	Hiç	1	1.8	4	9.1	5	5	
Akşam	Her Gün	53	94.6	37	84.1	90	90	$\chi^2=3.048$ $p=0.101$
	Arada Bir	3	5.4	7	15.9	10	10	
Kuşluk	Her Gün	9	16.1	7	15.9	16	16	$\chi^2=0.168$ $p=0.919$
	Arada Bir	30	53.6	22	50.0	52	52	
	Hiç	17	30.4	15	34.1	32	32	
İkinci	Her Gün	11	19.6	7	15.9	18	18	$\chi^2=0.233$ $p=0.890$
	Arada Bir	34	60.7	28	63.6	62	62	
	Hiç	11	19.6	9	20.5	20	20	
Yatsı	Her Gün	17	30.4	16	36.4	33	33	$\chi^2=0.963$ $p=0.618$
	Arada Bir	29	51.8	23	52.3	52	52	
	Hiç	10	17.9	5	11.4	15	15	

*Pearson Ki-Kare testi * $p<0.05$*

Sistemin obezite riskini yüksek olarak tahmin ettiği çocukların düşük riskli tahmin edilen çocuklara göre meyve ve sebze tüketim sıklıklarının düşük, fast-food, tereyağı, hamur işi, cips/kızartma, gazlı ve şekerli içecekler ve çikolata, bisküvi ve kraker tüketim sıklıklarının daha yüksek olduğu görülmüştür ($p<0.05$) (Tablo 4.20). Diğer besin ve besin grupları için gruplar arasında bir fark bulunamamıştır ($p>0.05$) (Tablo 4.20).

Tablo 4.20. Sistem Tahmin Sonuçlarına Göre Çeşitli Besinlerin Tüketim Sıklıklarının Dağılımı

		Obezite Riski Düşük (n=56)		Obezite Riski Yüksek (n=44)		Toplam (n=100)		χ^2 ve p
		n	%	n	%	n	%	
Süt ve ürünleri	Her Gün	43	76.8	30	68.2	73	73	$\chi^2=1.449$ p=0.485
	Arada Bir	10	17.9	9	20.5	19	19	
	Hiç	3	5.4	5	11.4	8	8	
Et ve Ürünleri	Her Gün	27	48.2	15	34.1	42	42	$\chi^2=2.182$ p=0.336
	Arada Bir	25	44.6	26	59.1	51	51	
	Hiç	4	7.1	3	6.8	7	7	
Tahıl Ürünleri	Arada Bir	24	42.9	25	56.8	49	49	$\chi^2=3.871$ p=0.144
	Hiç	6	10.7	7	15.9	13	13	
	Her Gün	26	46.4	12	27.3	38	38	
Meyve ve Sebze	Her Gün	47	83.9	28	63.6	75	75	$\chi^2=5.411$ p=0.020*
	Arada Bir	9	16.1	16	36.4	25	25	
Bal, reçel, pekmez vb.	Hiç	3	5.4	4	9.1	7	7	$\chi^2=549$ p=0.760
	Arada Bir	31	55.4	24	54.5	55	55	
	Her Gün	22	39.3	16	36.4	38	38	
Tereyağı	Hiç	11	19.6	7	15.9	18	18	$\chi^2=7.107$ p=0.029*
	Arada Bir	40	71.4	24	54.5	64	64	
	Her Gün	5	8.9	13	29.5	18	18	
Fastfood	Hiç	6	10.7	6	13.6	12	12	$\chi^2=8.636$ p=0.013*
	Arada Bir	50	89.3	32	72.7	82	82	
	Her Gün	0	0.0	6	13.6	6	6	
Hamur işi	Arada Bir	52	92.9	33	75.0	85	85	$\chi^2=6.162$ p=0.014*
	Her Gün	4	7.1	11	25.0	15	15	
Cips/kızartma vb.	Hiç	6	10.7	0	0.0	6	6	$\chi^2=8.889$ p=0.012*
	Arada Bir	48	85.7	37	84.1	85	85	
	Her Gün	2	3.6	7	15.9	9	9	
Gazlı/şekerli İçecekler	Hiç	5	8.9	2	4.5	7	7	$\chi^2=9.966$ p=0.007*
	Arada Bir	51	91.1	35	79.5	86	86	
	Her Gün	0	0.0	7	15.9	7	7	
Çikolata, bisküvi, kraker	Arada Bir	49	76.8	26	59.1	75	75	$\chi^2=10.606$ p=0.001*
	Her Gün	7	17.9	18	40.9	25	25	

Pearson Ki-Kare testi *p<0.05

Tablo 4.21. Sistem Tahmin Sonuçlarına göre Psikolojik ve Genetik Faktörlerin Dağılımı

		Obezite Riski Düşük (n=56)		Obezite Riski Yüksek (n=44)		Toplam (n=100)		χ^2 ve p
		n	%	n	%	n	%	
Çocuğun Travmatik Olay Yaşama Durumu	Hayır	54	96.4	35	79.5	89		$\chi^2=7.174$ p=0.01*
	Evet	2	3.6	9	20.5	11		
Ailede Obezite Varlığı	Hayır	49	87.5	34	77.3	83		$\chi^2=1.174$ p=0.279
	Evet	7	12.5	10	22.7	17		

Pearson Ki-Kare testi *p<0.05

Obezite riski yüksek olarak tahmin edilen çocukların travmatik olay (ailede kayıp, istismar, aile içi şiddet vb.) yaşama durumlarının obezite riski düşük olan çocuklara göre daha yüksek olduğu görülmüştür ($p<0.05$) (Tablo 4.21). Ailede obezite varlığına bakıldığında ise sistem tarafından obezite riski yüksek olarak tahmin edilen çocuklar ile obezite riski düşük olarak tahmin edilen çocuklar arasında istatistiksel olarak anlamlı fark bulunamamıştır ($p>0.05$)(Tablo 4.21).

Tablo 4.22. Sistem Çıktı Sonuçlarına göre Gün İçerisindeki Aktivite ve Ekran Sürelerinin Dağılımı

		Obezite Riski Düşük (n=56)		Obezite Riski Yüksek (n=44)		Toplam (n=100)		χ^2 ve p
		n	%	n	%	n	%	
Aktivite Süresi (saat)	≥ 2	16	28.6	8	18.2	24	24	$\chi^2=6.633$ $p=0.036^*$
	1-2	27	48.2	15	34.1	42	42	
	< 1	13	23.2	21	47.7	34	34	
Bilgisayar/ Tablet/ Telefon Başında Geçirdiği Süre (saat)	≥ 2	30	53.6	11	25.0	41	41	$\chi^2=8.685$ $p=0.013^*$
	1-2	17	30.4	24	54.5	41	41	
	< 1	9	16.1	9	20.5	18	18	
Televizyon Başında Geçirdiği Süre (saat)	≥ 2	17	30.4	15	34.1	32	32	$\chi^2=0.161$ $p=0.923$
	1-2	28	50.0	21	47.7	49	49	
	< 1	11	19.6	8	18.2	19	19	

*Pearson Ki-Kare testi * $p<0.05$*

Sistem tarafından obezite riski düşük olarak tahmin edilen çocukların obezite riski yüksek olarak tahmin edilen çocuklara göre gün içerisindeki aktivite sürelerinin anlamlı oranda daha uzun olduğu saptanmıştır. Ayrıca sistem tarafından obezite riski yüksek olarak tahmin edilen çocukların gün içerisinde bilgisayar, tablet, telefon başında geçirdikleri sürelerin ise obezite riski düşük olarak tahmin edilen çocuklara göre daha kısa olduğu saptanmıştır ($p<0.05$). Çocukların gün içerisinde televizyon karşısında geçirdikleri süre açısından gruplar arasında fark saptanmamıştır ($p>0.05$) (Tablo 4.22).

5. TARTIŞMA VE SONUÇ

Günümüzde yapay zekâ uygulamaları her alanda olduğu gibi sağlık alanında da oldukça popülerdir. Yapay zekâ teknolojisi, birçok hastalığın erken teşhisinde ve/veya birçok hastalığın da henüz ortaya çıkmadan hastalık riskini tahmin edilmesindeki etkinliğiyle sağlık alanında ciddi katkılar sağlayabilmektedir. Bu çalışmada önlenemez bir hızla artan, dünyanın ve ülkemizin en önemli sorunlarından biri olan obezite ele alınmıştır. Obezitenin çocukluk çağında henüz ortaya çıkmadan önlenmesi önemlidir. Çocuklarda obezite, özellikle 4-6 yaş aralığında ve gelişim çağında artış göstermektedir (HSGM, 2019). Bu sebeple çocukluk çağında obezite riski tahmin edilip gerekli tedbirler erken yaşta alınmadığında hastalığın ortaya çıktıktan sonra tedavisi daha da zorlaşmaktadır (Günöz 2010). Çocukluk çağında obezite, nadiren okullarda yapılan sağlık taramaları, dikkatli öğretmenlerin ebeveynleri yönlendirmeleri veya bilinçli ailelerin çocuğu dikkatli izlemeleri sayesinde fark edilebilse de çoğunlukla obezite ortaya çıkmadan fark edilmemektedir. Ancak çocukluk çağı obezite riski ile ilişkili parametreleri içeren yeterli sayıda veriye ulaşıldığında makine öğrenmesi yaklaşımları ile risk tahmini yapabilen otomatik bir sistemden bahsetmek mümkündür (Chollet, 2017).

Bu çalışma çocukluk çağı obezite risk tahmini işlemini gerçekleştiren, basit kullanım imkânı sunan, ebeveynlerin ücretsiz erişerek, kendi çocukları için belirlenen riski görebilecekleri web tabanlı ve dinamik bir erken uyarı sistemi üzerinedir. Çocukluk çağında obezitenin henüz ortaya çıkmadan tespit edilmesine ve alınacak önlemler sayesinde çocukların sağlıklı birer yetişkin olmalarına katkı sağlanması amaçlanmıştır. Mühendislik alanında çocukluk çağı obezite riskinin saptanmasında

makine öğrenmesi algoritmalarının başarılarının karşılaştırıldığı sınırlı sayıda çalışma mevcuttur (Abdullah ve ark., 2017; Adnan ve ark., 2012; Bulut ve ark., 2017; Ergün, 2009; Hammond ve ark., 2019; Heydari ve ark., 2017; Kim ve ark., 2019; Wiechman ve ark., 2017; Zhang ve ark 2009). Ancak, literatürde makine öğrenmesi yöntemleri ile Beslenme ve Diyetetik alanında yapılmış çocukluk çağı obezite risk tahmini yapan web tabanlı uyarı sistemi ile alakalı herhangi bir çalışma bulunmadığı için çalışma bu alanda yapılmış ilk çalışma özelliği taşımaktadır. Ayrıca çalışmada makine öğrenmesi algoritmalarının sınıflandırma başarılarının karşılaştırılmasının yanında, en yüksek başarıyla sınıflandırma işlemini gerçekleştiren algoritma kullanılarak, hali hazırda kullanılabilen web tabanlı dinamik bir sistemin kurulması da çalışmamızın özgün bir yapıda olduğunu göstermektedir.

Bu tez çalışması iki aşamadan oluşmaktadır.

Çalışmanın birinci aşamasında makine öğrenmesi algoritmalarının başarıları kıyaslanmıştır. En yüksek başarı ile sınıflandırma işlemini gerçekleştiren karar ağacı algoritması ile çocukluk çağı obezite riski için web tabanlı bir erken uyarı sistemi geliştirilmiştir.

Makine öğrenmesi uygulamalarının geliştirilmesinde hazır veri setleri veya çalışmacı tarafından hazırlanan özgün veri setleri kullanılmaktadır. Hazır veri setleri ile gerçekleştirilen makine öğrenmesi yaklaşımlarında veri setlerindeki eksik ve hatalı verilerin ayıklanması uzun ve zahmetli bir iştir. Ayrıca bu eksik ve hatalı veriler tam anlamıyla ayıklanmaz veya tamamlanmazsa bu sistemin başarısını ciddi anlamda etkileyen bir eksikliktir. Özgün hazırlanan veri setlerinin başarısı konuya yönelik hazırlandıkları için ve araştırmacı tarafından titizlikle toplandığı için hata şansı daha düşük olmaktadır. Ayrıca makine öğrenmesi uygulamalarında kullanılacak veri setinin, problemin tespiti ile en alakalı parametrelerden oluşması modelin başarısı ile yakından ilişkilidir (Şeker, 2013).

Literatüre bakıldığında; Zhang ve arkadaşlarının (2009) 0-3 yaş arasındaki çocukların obezite riskini tahmin etmek için çeşitli makine öğrenmesi algoritmalarının başarılarını inceledikleri bir çalışmada, çocukların vücut ağırlığı, boy uzunluğu ve BKİ değerleri başta olmak üzere 56 öznitelikten oluşan hazır bir

veri seti kullanılmıştır. Çalışmada 0-3 yaş grubunun obezite tahmini için erken bir yaş aralığı olduğunu, çocuğun sosyal, çevresel faktörlerden henüz etkilenmeye başlamadığı için tahmin işleminin başarılarının düşük olduğunu bildirmişlerdir. Bu çalışmada 4-6 yaş grubu çocukların tercih edilmesinin en önemli sebeplerinden biri, bu yaş grubu çocukların anaokulu ve kreş gibi ortamlarda sosyal çevrelerinden etkilenmeye başlamalarıdır. Hammond ve arkadaşları (2019) ise yaptıkları çalışmada elektronik sağlık kayıtlarında bebeklik ve erken çocukluk dönemindeki bilgileri içeren verilerden oluşan veri seti ile obezite riski tahmini gerçekleştirmişlerdir. Bir diğer çalışmada ise obezite tahmin modelinin geliştirilmesinde altıncı sınıf çocuklarına ait hem çocukların, hem de ailelerinin ve çevrelerinin bilgilerinin olduğu veri tabanındaki bir veri seti kullanılmıştır (Abdullah ve ark., 2017). Kim ve arkadaşları (2019) ise 12-18 yaş aralığındaki çocukların verilerinin olduğu hazır bir veri seti ile obezite riskinin tahmininde çeşitli makine öğrenmesi algoritmalarının başarılarını incelemişlerdir. Bir diğer çalışmada 5-7 yaş arasındaki 200 çocuğun verileri kaydedilerek veri seti hazırlanmıştır. Çalışmada çocuğa ait demografik özellikler, doğum haftası, doğum ağırlığı, anne sütü alma durumu, fiziksel aktivite düzeyi, televizyon ve internet karşısında geçirilen süre, şekerli içecek içme durumu, kahvaltı tüketim sıklığı, fastfood tüketim sıklığı, ailede obezite varlığı gibi obezite ile ilişkili temel risk faktörlerini içeren veri seti ile obezite için bir tahmin modeli önerilmiştir (Adnan ve ark., 2012). İspanyada yapılan bir çalışmada 2-5 yaş arasındaki 238 çocuğun medya kullanımı, demografik özellikleri, beslenme alışkanlıkları ve antropometrik ölçümlerini içeren özgün bir veri seti kullanılmıştır (Wiechmann ve ark., 2017). Bulut'un (2017) 7-15 yaş aralığındaki 61'i obez, 42'si normal ağırlıkta, toplam 103 çocuk üzerinde yürüttüğü çalışmada da antropometrik özellikler, psikolojik faktörler, ebeveynlere ait özellikler, aktivite ve ekran süresi, öğün sıklığı ve besin tüketim sıklığı ile alakalı 29 faktörden oluşan özgün veri seti kullanılmıştır. Bu çalışmada ise sistemin geliştirilmesinde obezitenin ilk temellerinin atıldığı 4-6 yaş aralığındaki 491'i normal ağırlıkta ve 294'ü hafif şişman-obez toplam 785 çocuğa ait özgün bir veri seti kullanılmıştır. Çalışmamızda literatürdeki çalışmalara benzer şekilde; çocukluk çağı obezitesi ile ilişkili çocuğun antropometrik ölçüm değerleri, demografik özellikleri, besin tüketim sıklıkları, öğün tüketim sıklıkları, psikolojik ve genetik faktörleri, fiziksel aktivite düzeyleri, televizyon ve

bilgisayar, tablet ve cep telefonu başında geçirdikleri inaktif süre, çocuklara ait yaşamın ilk 1000 gününe ait özellikler gibi 35 özneteliği içeren veriler kullanılmıştır. Veri seti konunun uzmanı diyetisyen (araştırmacı) tarafından literatüre uygun olarak hazırlanmış, özgün bir veri setidir.

Çalışmamızda çocukluk çağı obezite riski için erken uyarı sisteminin kurulmasında hangi makine öğrenmesi algoritmasının kullanılacağına karar vermek amacıyla denetimli öğrenme yöntemlerinden sınıflandırma işlemi gerçekleştiren algoritmaların performansları incelenmiştir. Sınıflandırma işlemi gerçekleştiren, lojistik regresyon, destek vektör makinesi, k-en yakın komşu, Naive Bayes, yapay sinir ağları ve karar ağacı algoritmalarına ait doğruluk (accuracy), duyarlılık (recall, sensitivity), hassasiyet (precision), F-ölçütü (F-score), MCC ve karmaşıklık matrisi (confusion matrix) metrikleri ölçülmüştür (Şeker, 2013).

Çalışmamızda kullanılan algoritmaların doğruluk değerleri sırasıyla J48 karar ağacı %94, yapay sinir ağı %87.3, lojistik regresyon %83.7, destek vektör makinesi %78.5, Naive Bayes %75.3 ve k- en yakın komşu %60.6'dır. Duyarlılık metrik değerine göre algoritmaların performansları sırasıyla J48 için 0.945, destek vektör makinesi (DVM) için 0.919, yapay sinir ağı (YSA) için 0.916, Naive Bayes (NB) için 0.818, lojistik regresyon (LR) için 0.86 ve k-en yakın komşu (kNN) için 0.73 olarak saptanmıştır. Algoritmaların hassasiyet metrik performansları ise J48 için 0.961, YSA için 0.884, LR için 0.87, DVM için 0.778, NB için 0.758 ve kNN için 0.670 olarak bulunmuştur. F-ölçüt değerlerine göre en yüksek performans değeri J48 algoritması için 0.953 iken diğer algoritmalar için sırasıyla YSA için 0.900, LR için 0.86), DVM için 0.842, NB için 0.81) ve kNN için 0.69 olarak saptanmıştır. MCC değerinde de en yüksek performans J48 (0.876) algoritmasının iken diğer algoritmaların değerleri sırasıyla YSA için 0.726, LR için 0.65), DVM için 0.52), NB için 0.45) ve kNN için 0.134 dır. Algoritmaların kappa istatistik değerine bakıldığında J48 (0.8756) algoritmasının performansının en yüksek olduğu görülmüştür. Diğer algoritmaların kappa istatistikleri performanslarının ise sırasıyla YSA için 0.7247, LR için 0.6539, DVM için 0.5108, NB için 0.440) ve kNN için 0.1332 olduğu görülmüştür. Tüm bu değerler incelendiğinde çocukluk çağı obezite

risk tahmini için en yüksek performansı gösteren algoritmanın J48 algoritması olduğu ve ardından YSA algoritmalarının geldiği görülmüştür.

Literatür incelendiğinde; çocukluk çağı obezitesinin teşhisinde birçok farklı algoritmanın kullanıldığı görülmüştür. Çocuklarda obezite ile ilişkili temel faktörler ile yapılan denetimli bir öğrenme çalışmasında obezite için kurulan tahmin modelinde genetik algoritma kullanılmıştır (Adnan ve ark., 2012). Hammond ve ark. (2019) ise yaptıkları çalışmada regresyon modeli kullanmışlar ve tahmin işlemini %86 doğruluk oranıyla gerçekleştirmişlerdir. Heydari ve arkadaşlarının (2012) yaptığı bir çalışmada ise yapay sinir ağı algoritması ile lojistik regresyon yönteminin obezite tespiti üzerindeki performansları karşılaştırılmıştır. YSA modelinin obezitenin teşhisinde diğer yonteme göre daha yüksek performansa sahip olduğu bildirilmiştir. Ergün (2009) yaptığı çalışmada, lojistik regresyon ve YSA algoritmalarının başarılarını karşılaştırmıştır. YSA algoritmasının çocukluk çağı obezite riski tahmini için doğruluk değeri %90.2 iken; LR algoritması için bu değerin %87.8 olduğu, hassasiyet değerinin ise YSA için 0.923 ve için LR 0.884 olduğunu bildirmiştir. Bizim çalışmamızda da YSA algoritmasının (doğruluk oranı %87.3, hassasiyet oranı 0.876) çocukluk çağı obezite riski için sınıflandırma başarısının LR algoritmasına (doğruluk oranı %83.7, hassasiyet oranı 0.884) göre daha yüksek olduğu görülmüştür. Ancak bizim çalışmamızda bahsedilen çalışmadan farklı olarak, karar ağacı algoritması en yüksek başarı ile sınıflandırma işlemini gerçekleştirmiştir.

Wiechman ve arkadaşlarının (2017) 2-5 yaş aralığındaki 238 çocuğa ait verilerle oluşturdukları özgün veri seti ile yaptıkları çalışmada çocukluk çağı obezitesinin tahmininde bu çalışmada olduğu gibi, en yüksek doğruluk oranının J48 algoritmasına ait olduğu bildirilmiştir. Abdullah ve arkadaşlarının (2017) yaptıkları bir çalışmada okul çağı çocuklarında obezite riskinin tahmini için J48, NB ve DVM algoritmalarının performansları incelenmiştir. Algoritmaların doğruluk oranlarının J48 için %82.63, NB %82.04 ve DVM %82 olduğu, hassasiyet oranlarının ise J48 için 0.6525, NB için 0.6408 ve DVM için 0.640 olduğu ve bu sebeple en yüksek sınıflandırma başarısının bizim çalışmamızda olduğu gibi J48 algoritmasına ait olduğu bildirilmiştir.

Bulut'un (2017) 103 çocuğun verilerinden oluşan özgün bir veri seti ile gerçekleştirdiği çocukluk çağı obezitesinin erken teşhisi ile ilgili çalışmada ise J48 algoritmasının MCC değeri 0,667 ve k-en yakın komşu algoritmasının MCC değeri 0.469 olarak bildirilmiştir. Bizim çalışmamızda ise J48 algoritmasının MCC değeri 0.876 ve kNN algoritmasının MCC değeri 0.134 olduğu saptanmıştır.

Balakrishnan ve arkadaşlarının (2012) diyabet riskini tahmin etmek için makine öğrenmesi algoritmalarını kullandıkları bir çalışmada, sistemin eğitimi için 140 hastaya ait 16 parametrelilik araştırmacı tarafından hazırlanmış veri seti kullanılmıştır. Çalışmada en yüksek doğruluk oranının %85 ile karar ağacı algoritmasına ait olduğu saptanmış ve sistem bu algoritma ile kurulmuştur (Balakrishnan ve ark., 2012).

Kronik böbrek yetmezliğinin erken teşhisi için, 11 ile 81 yaş aralığındaki 102 kronik böbrek yetmezliği hastasına ait 15 parametreden oluşan veri seti ile bir sistem geliştirilmiştir. Karar ağacı, Naive Bayes ve yapay sinir ağı algoritmalarının sınıflandırma başarıları test edilmiştir. Sistem, en yüksek başarı ile sınıflandırma işlemini %92,2 doğruluk oranı ile karar ağacı algoritması gerçekleştirdiği için bu algoritma ile kurulmuştur (Al- Hyari ve ark., 2013).

Salekin ve Stankovic (2016) tarafından yapılan bir çalışmada kronik böbrek hastalığının tespitinde k-en yakın komşu ve karar ağacı algoritmalarının başarıları test edilmiştir. Algoritmalar, 250 kronik böbrek yetmezliği hastasına ve 150 sağlıklı bireye ait olmak üzere toplam 400 kişinin kayıtlarından oluşan bir veri seti ile test edilmiştir. Karar ağacı algoritmasının hastalığın tespitinde k-en yakın komşu algoritmasından daha iyi performans gösterdiği belirtilmiştir.

Kadınlardaki demir eksikliği anemisinin teşhisine yönelik yapılan bir çalışmada kadınlardaki demir eksikliği anemisinin teşhisi için %92,97 doğrulukta sınıflandırma işlemi gerçekleştiren karar ağacı algoritması ile sistem geliştirilmiştir (Yurtay ve ark., 2012).

Yapılan bir diğer çalışmada; çocukların obezite riskini tahmin etmek için çeşitli makine öğrenmesi algoritmalarının başarıları incelenmiştir. Naive Bayes algoritmasının % 91.9, karar ağacı algoritmasının %85.2, lojistik regresyon algoritmasının %83.2, YSA algoritmasının %84.7, LibSVM algoritmasının %78.7 ve

başarı oranında tahmin işlemini gerçekleştirdiği görülmüştür. Bizim çalışmamızdan farklı şekilde bu çalışmada Naive Bayes algoritması en iyi sınıflandırma işlemini gerçekleştirmiştir (Zhang ve ark., 2009).

Literatüre bakıldığında yaş grupları farklı olsa dahi çocukluk çağı obezite risk tahmini için sınıflandırma modelleri geliştirilen çalışmaların birçoğunda çalışmamıza benzer şekilde en yüksek performansı J48 algoritmasının gösterdiği saptanmıştır (Zhang ve ark., 2009; Abdullah ve ark., 2017; Wiechman ve ark., 2017). Ancak diğer çalışmalarla karşılaştırıldığında bizim çalışmamızda, çocukluk çağı obezitesinin tahmininde J48 algoritmasının doğruluk metriklerinin daha yüksek olması dikkat çekicidir. Algoritmaların başarılarının sadece doğruluk oranı ile değerlendirilmesi eksik bir değerlendirme olabilmektedir. Algoritmanın doğruluk oranının yanında incelenen hassasiyet oranının 1 değerine yakınlığı modelin sınıflandırma işlemini gerçekleştirirken sahip olduğu hassasiyeti gösterir. Literatürde özgün veri setleri ile obezite riskini tahmin etmek için yapılan çalışmalar incelendiğinde özgün veri setlerinde ulaşılan veri sayılarının yaklaşık 100-200 civarında olduğu görülmüştür. Ancak makine öğrenmesi yöntemlerinin az sayıda örnekle veri setindeki örüntüyü yeterince öğrenememesinden dolayı, sınıflandırma performansı düşük olabilmektedir. Yüksek sayıdaki veriden oluşan veri setleri ise genelde hazır veri setleri olduğu için eksik/aykırı veri veya konu ile alakasız parametreler içerebildikleri için sınıflandırma başarısı düşük olabilmektedir. Bu çalışmada, araştırmayı yürüten diyetisyen (araştırmacı) tarafından doğru öznitelikler seçilerek oluşturulan özgün bir veri setinin kullanılması ve içeriğinde yüksek veri sayısına sahip olması, veri setinin nitelik ve nicelik açısından güçlü olmasını sağlamıştır. Bu durumun oluşturulan sistemin başarısına da yansıdığı düşünülmektedir.

Çalışmamızda en yüksek performansla tahmin işlemi gerçekleştiren J48 algoritması ile çocukluk çağı obezitesi riskini tahmin edebilen web tabanlı dinamik bir sistem kurulmuştur. Geliştirdiğimiz bu sistemde, veri setindeki normal ağırlıkta ve hafif şişman-obez çocukların çocukluk çağı obezitesi için risk faktörleri özelliklerini ve aralarındaki ilişkileri öğrenmektedir. Bu sayede sistem, girilen her yeni çocuğa ait veriyi daha önce öğrendiği bilgilerden yaptığı çıkarımlarla değerlendirip çocukluk çağı obezitesi için risk tahmini yapmaktadır.

Çalışmamızın ikinci aşamasında ise geliştirilen bu web tabanlı sistem ile sistemin geliştirilmesinde daha önce verileri kullanılmamış 100 çocuğun ailelerine kurulan sistem ile çocuklarının obezite risklerinin tahmin etmeleri sağlanmıştır. Ebeveynlerin sisteme girdikleri veriler ile sistemin tahmin sonucu kaydedilmiştir. Sistemin tahmin değeri ile çocukluk çağı obezitesi ile ilişkili öznitelikler arasındaki ilişki istatistiksel olarak değerlendirilmiştir.

Obezite riski sistem tarafından tahmin edilen çocukların %45'i erkek, %55'i kız çocuklardan oluşmaktadır (Şekil 4.9). Çocukların %24'ü 4 yaşında, %36'sı 5 yaşında ve %40'ı 6 yaşındadır (Şekil 4.10). Sistemin çocukların %56'sının obezite riskini düşük ve %44'ünün obezite riskini yüksek olarak tahmin ettiği görülmüştür (Tablo 4.15). Sistem tarafından obezite riski düşük olarak tahmin edilen çocukların BKİ ortalamalarının 14.76 ± 1.46 , obezite riski yüksek olarak tahmin edilen çocukların BKİ ortalamalarının ise 17.69 ± 2.3 olduğu saptanmıştır (Tablo 4.16). Sistem tarafından obezite riski düşük olarak tahmin edilen çocukların %17.9'unun zayıf, %78.6'sının normal, %3.6'sının hafif şişman-obez olduğu görülmüştür. Obez çocukların ise hiçbirinin obezite riskini düşük olarak tahmin etmediği görülmüştür (Tablo 4.17). Obezite riski yüksek olarak tahmin edilen çocukların ise %2.3'ünün zayıf, %59.1'inin normal, %9.1'inin hafif şişman, %29.5'inin obez olduğu görülmüştür (Tablo 4.17).

Sistem tahmin sonuçları ile çocukların doğum haftası, doğum ağırlığı, tek başına anne sütü alma süresi, toplam anne sütü alma süresi ve formula tüketme durumu arasında istatistiksel olarak anlamlı bir fark bulunamamıştır ($p > 0.05$) (Tablo 4.18). Literatürde çocuğun yaşamının ilk 1000 günü ile ilişkili parametrelerin obezite ile ilişkili olduğu bildirilmiştir (Mutlu, 2015; Woo ve ark., 2016; HSGM 2019) Ancak sistemin %94 başarı ile sınıflandırma yaptığı göz önünde bulundurulduğunda çıktı sonuçlarının tüm parametrelerle ilişkili sonuç bulmaması beklenen bir sonuçtur.

Öğün tüketim sıklıkları incelendiğinde sistemin obezite riskini yüksek olarak tahmin ettiği çocukların düşük riskli tahmin edilen çocuklara göre kahvaltı öğününü daha sık atladıkları görülmüştür ($p < 0.05$). Diğer öğünlerde fark bulunamamıştır ($p > 0.05$) (Tablo 4.19). Yapılan bir çalışmada kahvaltı öğününü tüketmeyen çocukların obez olma riskinin yapanlara oranla 1.5 kat fazla olduğu bildirilmiştir (Pekcan, 2011). Bir

diğer çalışmada da hafif şişman çocukların, diğer sağlıklı ağırlıktaki çocuklara oranla kahvaltı öğününü daha sık atladıkları ve kahvaltıda daha az besin tüketip, gün içinde birçok kez fazla miktarda besin atıştırdıkları bildirilmiştir (Noğay ve Köksal, 2012).

Çalışmamızda sistemin obezite riskini yüksek olarak tahmin ettiği çocukların düşük riskli tahmin edilen çocuklara göre meyve ve sebze tüketim sıklıklarının düşük, fast-food, tereyağı, hamur işi, cips/kızartma, gazlı ve şekerli içecekler ve çikolata, bisküvi ve kraker tüketim sıklıklarının daha yüksek olduğu görülmüştür ($p<0.05$) (Tablo 4.20). Obezite riski ile ilişkili çevresel faktörlerden en önemlisi beslenme alışkanlığıdır. Günümüzde kolay ulaşılabilen, uygun fiyatlı, lezzetli ve yüksek enerji yoğunluğuna sahip besinler bulunmaktadır. Bu çevresel şartlar sonucunda da fazla enerji alımı tetiklenmektedir. Çocukluk çağında meyve ve sebze tüketiminin az olması obezite için bir risk faktörüdür. Sebze ve meyveler yüksek antioksidan içeriği ve düşük enerji içeriği ile sağlıklı beslenme ve obeziteden korunma açısından oldukça önemli besin gruplarıdır (Alphan, 2011). Yağ ve enerji içeriği yüksek besinlerin çocukların kolaylıkla ulaşabileceği yerlerde satılması çocukluk çağı obezitesi için ciddi risk oluşturmaktadır (Noğay ve Köksal, 2012). Çocukluk çağında tüketimi fazla olan basit şeker içerikli besinler; günlük alınan enerji miktarını yükselterek obezite ve ilişkili hastalıkların ortaya çıkma riskini artırabilmektedir (Bachman ve ark., 2006; Köksal ve Karaçil, 2014). Yapılan çalışmalarda, çocukluk çağı obezitesi ile paralel olarak gazlı şekerli içecek tüketiminin arttığı da belirtilmektedir (Corsica ve Hood, 2011; Ruyter ve ark., 2012; Köksal ve Karaçil, 2014). Danimarka'da dokuz yaşındaki çocuklar ile yapılan prospektif bir çalışmada, günde birden fazla şekerli içecek tüketen çocukların 15 yaşında BKİ değerlerinin ve bel çevrelerinin diğer çocuklara göre anlamlı oranda arttığı saptanmıştır. (Zheng ve ark., 2014). Bir diğer çalışmada, 4-10 yaş arası 4.164 çocuğun şekerli içecek ve yüksek yağlı yiyecek tüketimleri ile BKİ değerleri arasındaki ilişki incelenmiş ve bu tür boş enerji kaynağı besinlerin BKİ değerini artırdığı saptanmıştır. Obezite riskinin azaltılmasına katkı sağlamak için çocukluk çağında bu tür boş enerji kaynağı yiyeceklerin ve içeceklerin tüketiminin olabildiğince azaltılması gerektiği vurgulanmaktadır (Millar ve ark., 2014). Deobar ve arkadaşlarının (2013) yaptıkları bir çalışmada, iki-beş yaş arası çocukların şekerli içecek tüketimi ile BKİ değerleri arasındaki ilişki incelenmiştir. Çalışmada beş yaş grubunda düzenli olarak şekerli

iecek tketen ocuklarda obezite grlme riskinin anlamlı derecede yksek olduėu saptanmıřtır. Aynı alıřmada iki yař grubunda ise, dzenli řekerli iecek tketen ocuklarda, imeyenlere gre takip eden iki yıl iinde BKİ deėerlerinin anlamlı derecede artabileceėini bildirilmiřtir. Mozaffarian ve arkadaşlarının (2011) yaptıkları bir alıřmada, ocukların % 21.8'inin BKİ'si ≥ 95 . persentil, %39.8'inin ise BKİ'si ≥ 85 . persentil bulunmuřtur. Hafif řiřman ve obez ocukların meyve ve sebze tketimlerinin az olduėu, kızarmıř yiyecekler, hamur iřleri ve řekerli yiyecek-ieceklerin tketimlerinin yksek olduėu bildirilmiřtir. Yksek karbonhidrat, yaė ve enerji ieren besinlerin ařır tketimi de ocukluk aėında obezite riskini artırmaktadır. Yapılan alıřmalar kahvaltılık gevrekler, řekerli iecekler, kekler ve biskvilerin tketiminin ocukluk dneminde hızla arttıėını bildirmektedir (Clifton ve ark., 2011; Deober ve ark., 2013). Ayrıca bu tr yksek miktarda basit karbonhidrat ieren besinlerin glisemik indeksinin de yksek olması sebebiyle alıėı daha erken srede tetikleyerek ocukların ařır yemelerine de sebep olarak obezite riskini artırabilmektedir (Deober ve ark., 2013). Okul ncesi ocuklarda yapılan bir alıřmada ocukların gnlk enerji alımları incelendiėinde, eklenmiř řekerden gelen enerjinin toplam enerjinin %25'inden fazla olması durumunda, ocukların gnlk besin ėesi alımlarının azaldıėı ve obezite riskinin arttıėı bildirilmiřtir (Pulgaron, 2013).

Bu alıřmada obezite riski yksek olarak tahmin edilen ocukların travmatik olay yařama durumlarının obezite riski dřk olan ocuklara gre anlamlı derecede yksek olduėu grlmřtr ($p < 0.05$) (Tablo 4.21). Literatr incelendiėinde ocukluk aėında travmatik bir olay yařama durumu ile yeme bozukluėu ve obezite arasında anlamlı bir iliřkinin olduėu varsayılmaktadır (Keel ve Klump 2003; Andersen ve Yager 2005; Kundakı, 2005). Yapılan alıřmalar, anksiyete, depresyon, kızgınlık, cinsel istismar gibi olumsuz psikolojik durumların obezite geliřme riski ile iliřkili olduėunu gstermektedir (Gustafson ve Sarwer, 2004; Hawkins ve Stewart, 2012). ocukluk dneminde yařanılan travmalar ile obezite geliřimi arasındaki iliřkinin; psikolojik travmalara verilen psikolojik tepkilerin veya yeme davranıřında meydana gelen bozuklukların obezite geliřimine neden olabileceėi bildirilmiřtir (Hawkins ve Stewart, 2012).

Bu çalışmada sistemin obezite riskini düşük olarak tahmin ettiği çocukların obezite riski yüksek olarak tahmin edilen çocuklara göre gün içerisindeki aktivite sürelerinin daha uzun olduğu saptanmıştır ($p<0.05$) (Tablo 4.22). Çocuklarda fiziksel aktiviteye ayrılan sürenin azlığı ile obezite arasında pozitif ilişki olduğu da bilinmektedir (Musaiger ve Mannai 2014). Fiziksel aktivite ve oyun oynamanın dil becerisi, paylaşma alışkanlığı, çevreyi tanıma, merak duygusunun giderilmesi ve hayal etme becerisi kazanma gibi faydaları da vardır (Horzum ve ark., 2008). Yapılan çalışmalar fiziksel aktivite süresi düşük olan çocuklarda obezitenin daha sık görüldüğünü ve fiziksel aktivitenin artırılması ile birlikte obezite sıklığının da azalabileceğini göstermiştir (Vandewater ve Cummings 2008; Fulton ve ark., 2009). Decelis ve arkadaşlarının (2014) yaptıkları bir çalışmada, obez çocukların normal vücut ağırlığına sahip çocuklara göre fiziksel aktivite sürelerinin daha az olduğu, obezlerin günlük aktivitesinin ihtiyacın üçte biri kadar olduğu bildirilmiştir.

Literatürün tersinde bir sistem sonucunun tek bir parametrede olduğu görülmüştür. Çalışmamızda literatürün tam tersi şekilde sistem tarafından obezite riski yüksek olarak tahmin edilen çocukların gün içerisinde bilgisayar, tablet, telefon başında geçirdikleri sürelerin obezite riski düşük olarak tahmin edilen çocuklara göre daha kısa olduğu saptanmıştır ($p<0.05$) (Tablo 4.22). Ancak literatürde uzun süre bilgisayar, tablet, cep telefonu gibi cihazlar ile internet ortamında geçirilen zamanın fazla olması ve oyun bağımlılığı ile obezite arasında pozitif ilişki olduğu bilinmektedir (Musaiger ve Mannai 2014). Okul öncesi dönemde internette geçirilen sürenin artması ile çocukların sosyal, zihinsel, biyolojik ve psikolojik gelişimini de negatif etkileyebilmektedir. Bir çalışmada çocukların bilgisayar bağımlılığı ile obezite arasında anlamlı ilişki olduğu bildirilmiştir (Ortega ve Ruiz 2007). Bilgisayar, tablet, cep telefonu başında geçirilen sürenin metabolizma hızını düşürdüğü, enerji harcamasını azalttığı, beslenme ekran karşısında iken tüketilen atıştırmalıkların artması, ayaküstü hazır besinlerin tüketimi, izlerken yemek yeme alışkanlığı, şekerli içecek tüketimi, porsiyonların büyüklüğü gibi birçok neden çocukluk çağında obezite riskinin artmasına neden olmaktadır (Cleland ve ark., 2008 Baranowski ve Baranowski, 2011). Ancak sistemin %94 başarı ile sınıflandırma işlemi gerçekleştirdiği göz önünde bulundurulduğunda %6'lık hata payı hali hazırda beklenmektedir. Literatürün tersinde sonuç veren başka bir parametre olmaması

sistemimizin başarısının bir göstergesidir. Daha fazla veri ile ve ileri yapay zeka teknolojileri ile sistemin başarısı artırılabilir.

Sonuç ve Öneriler;

- Sistemin kurulumunda kullanılan veri setinde 491 normal ve 294 hafif şişman-obez olmak üzere toplam 785 çocuğun verileri kullanılmıştır. Çocukların %48.4'ü erkek ve %51.6'sı kızlardan oluşmaktadır. Çocukların %27.4'ü 4 yaşında %36.6'sı 5 yaşında ve %36.1'i 6 yaşındadır. Ailenin gelir durumu incelendiğinde %52.1'inin geliri giderine eşit, %10.3'ünün geliri giderinden az ve %37.6'sının geliri giderinden fazla olduğu görülmüştür. Çocukların annelerinin %14.9'unun lisansüstü, %57.1'inin lisans, %15.7'sinin lise ve %12.4'ünün ilköğretim mezunu olduğu saptanmıştır. Çocukların annelerinin %17.2'sinin sağlık personeli, %35.5'inin devlet memuru, %6.8'inini işçi, esnaf gibi diğer meslek gruplarında olduğu ve %40.5'inin ise ev hanımı olduğu görülmüştür. Babaların %37.6'sının çalışmadığı ve %35'inin ise işçi, esnaf, çiftçi, şoför gibi diğer meslek gruplarında yer aldığı belirlenmiştir. Gruplar arasında demografik özellikler bakımından bir fark saptanmamıştır. (Tablo 4.1).
- Sistemin kurulumunda verileri kullanılan çocukların ortalama vücut ağırlıkları 20.88 ± 4.99 kg ve boy uzunlukları 111.3 ± 0.096 cm ve BKİ değerleri 16.85 ± 3.535 kg/m² olduğu saptanmıştır. Gruplara göre değerlendirildiğinde, zayıf-normal grubun ortalama vücut ağırlığı 18.95 ± 3.029 kg ve boy uzunluğu 110 ± 7.76 cm ve BKİ değeri 14.9 ± 1.41 kg/m² olduğu; hafif şişman-obez grubun ise ortalama vücut ağırlığı 24.12 ± 4.995 kg ve boy uzunluğu 107.5 ± 7.521 cm ve BKİ değeri 20.2 ± 3.57 kg/m² olduğu saptanmıştır. Hafif şişman-obez çocukların vücut ağırlığı ve BKİ ortalamalarının normal çocuklara göre anlamlı derecede yüksek olduğu boy uzunluklarının ise düşük olduğu görülmüştür ($p < 0.05$) (Tablo 4.2).
- Sistemin kurulumunda verileri kullanılan çocukların %78.7'sinin 37-40 hafta arasında, %10.7'sinin 37. haftadan önce ve %10.6'sının 40. haftadan sonra doğduğu görülmüştür. Doğum ağırlıkları incelendiğinde %85.5'inin 2500-

4000 g arasında, %7.1'inin 2500 g'ın altında ve %7.4'ünün ise 4000 g'ın üstünde doğduğu belirlenmiştir. Çocukların %67'sinin ilk 6 ay tek başına anne sütü aldığı, %33'ünün ise 6 aydan az süre tek başına anne sütü aldığı belirlenmiştir. Toplam anne sütü alma sürelerine bakıldığında; %73'ünün 12 aydan fazla süre ve %27'sinini 12 aydan az süre anne sütü aldığı saptanmıştır. Çocukların %58.1'inin formüla mama tüketmediği ve %41.9'unun ise formüla mama tükettiği görülmüştür. Gruplara göre incelendiğinde; hafif şişman-obez gruptaki çocukların %81.6'sı 2500-4000 g arasında, %7.8'i 2500 g'ın altında, %10.5'i 4000 g'ın üstünde ve normal gruptaki çocukların %87.8'i 2500-4000 g arasında, %6.7'si 2500 g'ın altında % 5.5'i 4000 g'ın üstünde olduğu görülmüştür, Hafif şişman-obez grupta doğum ağırlığı 4000 g üstünde olan çocukların oranının normal gruptaki çocuklara göre anlamlı derecede yüksek olduğu saptanmıştır ($p<0.05$) (Tablo 4.3).

- Sistemin kurulumunda verileri kullanılan çocukların öğün tüketim sıklıkları incelendiğinde; sabah öğününü %93.9'unun her gün ve %6.1'inin arada bir tükettiği, öğle öğününü %66.9'unun her gün, %30.7'sinin arada bir tükettiği ve %2.4'ünün ise hiç tüketmediği, akşam öğününü %94.9'unun her gün ve %5.1'inin ise arada bir tükettiği, kuşluk öğününü %15.1'inin her gün, %42.8'inin arada bir tükettiği ve %41.9'unun hiç tüketmediği, ikindi ara öğününü ise %24.1'inin her gün, %56.8'inin arada bir tükettiği ve %19.1'inin hiç tüketmediği, yatsı ara öğününü %36.1'inin her gün, % 48.7'sinin arada bir tükettiği ve %15.3'ünün hiç tüketmediği saptanmıştır. Gruplara göre incelendiğinde hafif şişman-obez çocukların kahvaltı ve akşam öğününü her gün tüketim durumlarının normal gruba göre anlamlı derecede yüksek olduğu saptanmıştır. Diğer öğünlerde gruplar arasında bir fark saptanmamıştır ($p<0.05$) (Tablo 4.4).
- Sistemin kurulumunda verileri kullanılan çocukların süt ve ürünlerini %78.3'ünün her gün ve %21.7'sinin arada bir tükettiği, et ve ürünlerini %34.3'ünün her gün ve % 65.7'sinin arada bir tükettiği görülmüştür. Tahıl ve ürünlerinin tüketim sıklığına bakıldığında ise %42.3'ünün her gün, %48.9'unun arada bir tükettiği ve %8.3'ünün ise hiç tüketmediği görülmüştür. Meyve ve sebze grubundaki besinlere bakıldığında çocukların

%81'inin her gün %18.9'unun arada bir tükettiği saptanmıştır. Bal, reçel, pekmez gibi şekerli besinleri çocukların %11.6'sının hiç tüketmediği, %56.7'sinin arada bir ve % 31.7'sinin ise her gün tükettiği görülmüştür. Tereyağı %15.4'ünün hiç tüketmediği, %57.1'inin arada bir ve %27.5'inin her gün tükettiği görülmüştür. Fast food tarzı yüksek yağ ve enerji içeren besinleri ise %20.5'inin hiç tüketmediği, %76.6'sının arada bir ve %2.9'unun hiç tüketmediği belirlenmiştir. Hamur işini %1.1'inin hiç tüketmediği, %91.1'inin arada bir ve %7.8'inin her gün tükettiği görülmüştür. Cips, kızartma vb. gibi yüksek yağ ve enerji içeren besinleri ise %7.4'ünün hiç tüketmediği, %85.2'sinin arada bir ve %7.4'ünün her gün tükettiği saptanmıştır. Gazlı ve şekerli içecekleri çocukların %34'ünün hiç tüketmediği, %60.8'inin arada bir tükettiği ve %5.2'sinin her gün tükettiği belirlenmiştir. Çikolata, bisküvi, kraker vb. gibi paketli ve işlenmiş yüksek yağ, karbonhidrat ve enerji içeren besinleri ise %2.2'sinin hiç tüketmediği, %70.1'inin arada bir ve %27.8'inin her gün tükettiği görülmüştür. Gruplara göre bakıldığında hafif şişman-obez gruptaki çocukların et ve ürünlerini her gün tüketim durumlarının normal gruptaki çocuklara göre anlamlı derecede yüksek olduğu görülmüştür ($p<0.05$). Diğer besinlerde gruplar arasında bir fark saptanmamıştır (Tablo 4.5).

- Sistemin kurulumunda verileri kullanılan çocukların %83.3'ünün hiç travmatik bir olay yaşamadığı %16,7'sinin ise en az bir kez travmatik bir olay yaşadıkları saptanmıştır. Gruplar arasında bir fark saptanmamıştır (Tablo 4.6).
- Sistemin kurulumunda verileri kullanılan çocukların Ailede obezite varlığına bakıldığında %70.7'sinin ailesinde obez birey olmadığı ancak %29.3'ünün ailesinden az bir obez birey olduğu görülmüştür (Tablo 4.6). Gruplara göre bakıldığında ise normal gruptaki çocukların %25.5'inin, hafif şişman-obez gruptakilerin ise %35.7'sinin ailelerinde obez birey olduğu görülmüştür ($p<0.05$) (Tablo 4.6).
- Sistemin kurulumunda verileri kullanılan çocukların gün içerisinde toplam aktivite süreleri incelendiğinde çocukların %31.6'sının 2 saat üstü, %33.2'sinin 1-2 saat ve %35.2'sinin 1 saatin altında aktivite yaptıkları görülmüştür.

Bilgisayar, tablet, telefon gibi cihazlarla internet başında ders dışı geçirilen süreler bakıldığında %40.3 ünün 1 saatin altında, %24.6 sinin 1-2 saat ve %35.2 sinin 2 saat üstünde zaman geçirdiği; televizyon başında geçirilen süreler bakıldığında ise %55 inin 1 saatin altında, %28 inin 1-2 saat ve %16.9 unun 2 saatin üstünde zaman geçirdikleri saptanmıştır. Gün içerisindeki aktivite süresi, televizyon ve bilgisayar, tablet, cep telefonu karşısında geçirilen süreler bakımından gruplar arasında bir fark bulunamamıştır (Tablo 4.7).

- NB modeli %75.2866 doğruluk oranı ile verileri sınıflandırmıştır. NB algoritması ile kurulan model ile 785 verinin 591 adeti doğru sınıflandırılmıştır. NB modelinin duyarlılık oranının 0.888, hassaslık oranının 0.758, F-ölçütünün 0.818 ve kappa istatistiğinin 0.4404 MCC değerinin 0.454 olduğu saptanmıştır (Şekil 4.3).
- IBk modeli %60.6369 doğruluk oranı ile verileri sınıflandırmıştır. IBK algoritması ile kurulan model 785 verinin 476 adetini doğru sınıflandırmıştır. IBk modelinin duyarlılık oranının 0.731, hassaslık oranının 0.670, F-ölçütünün 0.699, MCC değerinin 0.134 ve kappa istatistiğinin 0.1332 olduğu saptanmıştır (Şekil 4.4).
- YSA modeli %87.2611 doğruluk oranı ile verileri sınıflandırmıştır. YSA algoritması ile kurulan model 785 verinin 685 adetini doğru sınıflandırmıştır. YSA modelinin duyarlılık oranının 0.916, hassaslık oranının 0.884, F-ölçütünün 0.900, MCC değerinin 0.726 ve kappa istatistiğinin 0.7247 olduğu saptanmıştır (Şekil 4.5).
- J48 Karar Ağacı modeli %94.1401 doğruluk oranı ile verileri sınıflandırmıştır. J48 algoritması ile kurulan model 785 verinin 739 adetini doğru sınıflandırmıştır. J48 Modelinin duyarlılık oranının 0.945, hassaslık oranının 0.961, F-ölçütünün 0.953, MCC değerinin 0.876 ve kappa istatistiğinin 0.8756 olduğu saptanmıştır (Şekil 4.6)
- Lojistik regresyon modeli %83.6943 doğruluk oranı ile verileri sınıflandırmıştır. Lojistik regresyon algoritması ile kurulan model 785 verinin 657 adetini doğru sınıflandırmıştır. Lojistik regresyon modelinin duyarlılık

oranının 0.862, hassaslık oranının 0.876, F-ölçütünün 0.869, MCC değerinin 0.654 ve kappa istatistiğinin 0.6539 olduğu saptanmıştır (Şekil 4.7).

- Destek vektör makinesi modeli %78.4713 doğruluk oranı ile verileri sınıflandırmıştır. LibSVM algoritması ile kurulan model 785 verinin 616 adetini doğru sınıflandırmıştır. LibSVM modelinin duyarlılık oranının 0.919, hassaslık oranının 0.778, F-ölçütünün 0.842, MCC değerinin 0.529 ve kappa istatistiğinin 0.5108 olduğu saptanmıştır (Şekil 4.8).
- J48 algoritmasının doğruluk oranı, hassasiyet, F-ölçütü ve kappa istatistik değerleri diğer algoritmalarından daha yüksek bulunmuştur (Tablo 4.14). Bu sebeple sistemin kurulmasında J 48 (karar ağacı) modelinin kullanılmasına karar verilmiştir.
- Sistem tarafından obezite riski yüksek tahmin edilen çocuklar ile obezite riski düşük tahmin edilen çocuklar arasında cinsiyet, yaş, gelir durumu, annenin eğitim durumu ve annenin mesleği açısından istatistiksel olarak anlamlı bir fark görülmemiştir ($p>0.05$) (Tablo 4.15)
- Obezite riski düşük çocukların babalarının sağlık çalışanı ve memur olma durumunun obezite riski yüksek çıkan çocuklara göre anlamlı derecede yüksek olduğu görülmüştür. Obezite riski yüksek çocukların babalarının meslekleri ise daha çok serbest meslek, esnaf, çalışmıyor vb. gibi diğer mesleklerden olduğu görülmüştür ($p<0.05$) (Tablo 4.15)
- Sistem tarafından obezite riski düşük olarak tahmin edilen çocukların BKİ ortalamalarının 14.76 ± 1.46 , obezite riski yüksek olarak tahmin edilen çocukların BKİ ortalamalarının ise 17.69 ± 2.3 olduğu saptanmıştır (Tablo 4.16).
- Sistem tarafından obezite riski düşük olarak tahmin edilen çocukların %17.9 unun zayıf, %76.9 unun normal, %5.4 ünün hafif şişman olduğu görülmüştür. Obez çocukların ise hiç birinin obezite riskini düşük olarak tahmin etmediği görülmüştür (Tablo 4.17).
- Sistem tarafından obezite riski yüksek olarak tahmin edilen çocukların %2.3 ünün zayıf, % 49.9 unun normal %20.5 ini hafif şişman %27.3 ünün obez olduğu görülmüştür (Tablo 4.17).
- Sistem tahmin sonuçları ile çocukların doğum haftası, doğum ağırlığı, tek başına anne sütü alma süresi, toplam anne sütü alma süresi ve formula

tüketme durumu arasında istatistiksel olarak anlamlı bir fark bulunamamıştır ($p>0.05$) (Tablo 4.18).

- Sistemin obezite riskini yüksek olarak tahmin ettiği çocukların düşük riskli tahmin edilen çocuklara göre kahvaltı öğününü daha sık atladıkları görülmüştür ($p<0.05$). Diğer öğünler istatistiksel olarak anlamlı bir fark bulunamamıştır (Tablo 4.19).
- Sistemin obezite riskini yüksek olarak tahmin ettiği çocukların düşük riskli tahmin edilen çocuklara göre meyve ve sebze tüketim sıklıklarının düşük, fast-food, tereyağı, hamur işi, cips/kızartma, gazlı ve şekerli içecekler ve çikolata, bisküvi ve kraker tüketim sıklıklarının istatistiksel olarak anlamlı derecede yüksek olduğu görülmüştür ($p<0.05$) (Tablo 4.20).
- Obezite riski yüksek olarak tahmin edilen çocukların travmatik olay yaşama durumlarının obezite riski düşük olan çocuklara göre anlamlı derecede yüksek olduğu görülmüştür ($p<0.05$) (Tablo 4.21).
- Sistemin obezite riskini düşük olarak tahmin ettiği çocukların obezite riski yüksek olarak tahmin edilen çocuklara göre gün içerisindeki aktivite sürelerinin ve gün içerisinde bilgisayar, tablet, telefon başında geçirdikleri sürelerin daha yüksek olduğu saptanmıştır ($p<0.05$) (Tablo 4.22).

Bu çalışmanın amacı, çeşitli makine öğrenmesi algoritmalarının başarılarını test etmek değil sağlık alanında işe yarar ve güvenilir sonuçlar verebilen özgün bir sistem kurmaktır. Sonuç olarak çocukluk çağı obezite riski için erken uyarı sistemi kurulabilmiş ve çağımızın en ciddi problemlerinden olan obezite için gerekli önlemlerin henüz ortaya çıkmadan alınabilmesi mümkün hale gelmiştir. Çalışmada çalışmacı tarafından hazırlanan, orijinal, güvenilir ve gerçek veri seti kullanılarak karar ağacı algoritması ile çocukluk çağı obezitesi riskini tahmin edebilen web tabanlı dinamik bir erken uyarı sistemi oluşturulmuştur. Veri setindeki verilerden çocukların özelliklerini öğrenerek çocukluk çağı obezitesi için risk faktörleri arasındaki ilişkileri öğrenip girilen yeni girilen her veri için “obezite riski yüksek” veya “obezite riski düşük” tahmininde bulunan akıllı bir sistemdir. Geliştirilen bu web tabanlı sistem ile sistemin geliştirilmesinde daha önce verileri kullanılmamış 100 çocuğun ailelerine kurulan sistem ile çocuklarının obezite risklerinin tahmin etmeleri sağlanmıştır. Sistemin tahmin değeri ile çocukluk çağı obezitesi ile ilişkili

öznitelikler arasındaki veriler değerlendirildiğinde sistemin tahmin işlemini başarı ile gerçekleştirdiği söylenebilir

Bu çalışma gelecekte, çocukluk çağı obezitesi ile ilişkili daha fazla parametre ve daha fazla sayıda veriden oluşan veri setleriyle farklı makine öğrenmesi yöntemleri veya derin öğrenme, bulanık mantık gibi daha ileri teknolojilerle tekrarlanabilir.

Sonuç olarak, bu çalışmanın sağlık bilimleri ve makine öğrenmesi uygulamaları konusunda çalışan araştırmacılar için değerli olacağı düşünülmektedir. Bu çalışmadaki tüm sonuçların, öncelikle diyetisyenler olmak üzere, tüm sağlık uzmanlarına, araştırmacılara gelecekte yapılacak çalışmalar için rehber olacağı ümit edilmektedir. Gelişen teknolojik dünyada makine öğrenmesi gibi ileri teknolojilerin sağlık alanına hızla entegre olduğu ancak bu alandaki çalışmaların yetersiz olduğu görülmektedir. Bu minvalde, çalışmanın tasarım ve literatürde öncül bir çalışma olarak bu tür çalışmaların sayısının arttırılabilmesi ve benzer çalışmaların geliştirilmesi amacıyla diğer çalışmalara yol göstereceği düşünülmektedir.



7.KAYNAKLAR

- Adnan MH, Husain W, Rashid N. Parameter identification and selection for childhood obesity prediction using data mining, 2nd International Conference on Management and Artificial Intelligence, Bangkok 7-8 Nisan 2012; pp 67-70.
- Akgün M. Kariyer Planlama İçin Karar Destek Sistemi. Yüksek Lisans Tezi, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, Ankara 2019; ss 50-85.
- Akpınar H. Veri tabanlarında bilgi keşfi ve veri madenciliği. İstanbul Üniversitesi İşletme Fakültesi Dergisi, 2000; 29: 1-22.
- Al-Hyari AY Al-Tae AM, Al-Tae MA. Clinical decision support system for diagnosis and management of chronic renal failure, Jordan Conference on Applied Electrical Engineering and Computing Technologies (AEECT), Amman 3-5 Aralık 2013; pp 1-6.
- Alpaydın E. Introduction to Machine Learning (2 nd ed). MIT Press, Cambridge 2010; pp 34-48.
- Alphan E. Çocuk ve ergen beslenmesinde obezogenik çevre, Başkent Üniversitesi SBF Beslenme ve Diyetetik Bölümü ve BESVAK işbirliği ile düzenlenen Çocuk ve Ergenlerde Ağırlık Yönetimi Kurs Programı, Ankara 17-19 Nisan 2009; ss 126-135.
- Alsharairi NA, Somerset SM. Skipping breakfast in early childhood and its associations with maternal and child BMI: a study of 2-5-year-old Australian children. Eur J Clin Nutr, 2016; 70(4): 450-455.
- Alvisi P, Brusa S, Alboresi S, Amarri S, Bottau P, Cavagni G. Recommendations on complementary feeding for healthy, full-term infants. Ital J Pediatr, 2015; 28: 36-41.
- Andersen AE. Yager J. Yeme Bozuklukları. Çeviri: Bozkurt A. Güneş Kitabevi, Ankara 2007; ss 85-96.
- Anderson AD, Solorzano CM, McCartney CR. Childhood obesity and its impact on the development of adolescent PCOS. Semin Reprod Med, 2014; 32(3): 202–213.
- Anderson KL. A Review of the prevention and medical management of childhood obesity. Child Adolesc Psychiatr Clin N Am, 2018; 27(1): 63-76.

- Anderson SE, Whitaker RC. Household routines and obesity in us preschool-aged children. *Pediatrics*, 2010; 125: 420–427.
- Anselma L, Mazzei, A, De Michieli F. An artificial intelligence framework for compensating transgressions and its application to diet management. *J Biomed Inform*, 2017; 68: 58–70.
- Arslan N. Obezite tedavisi: Beslenme. *Türkiye Klinikleri J Pediatri Sci*, 2015; 11 (3): 76-82.
- Ashley P, Gilbert SR. Obesity in pediatric trauma. *Orthop Clin North Am*, 2018; 49(3): 335-343.
- Atan, S. kNN, naive bayes ve karar ağacı makine öğrenme algoritmaları, bu algoritmaların sosyal bilimlerde kullanım imkânları. *ResearchGate*, 2020; 1-20.
- Ateş İ, Git Nedir? Github Kullanımı ve Temel Seviye Komutlar, 2020. [<https://engineering.teknasyon.com/git-nedir-github-kullan%C4%B1m%C4%B1-ve-temel-seviye-komutlar-182786c2d218>] Erişim tarihi: 10 Mart 2022.
- Avrupa gıda ve beslenme eylem planı 2015–2020. Avrupa Bölge Komitesi 64. Oturum. Kopenhag 15–18 Eylül 2014; ss 23-28.
- Aydın KE. Web İçerik Sınıflandırması İçin Makine Öğrenmesi Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 2020; ss 46-91
- Bachman MC, Baranowski T, Nicklas T. Is there an association between sweetened beverages and adiposity? *Nutr Rev*, 2006; 64: 153-74.
- Balakrishnan V, Shakouri M, Hoodeh H. Predictions using data mining and cased-based reasoning: A case study for retinopathy. *World Academy of Science, Engineering and Technology*, 2012; 6(3): 55-59.
- Bally L, Dehais J, Nakas CT, Anthimopoulos M, Laimer M, Rhyner D, Rosenberg G, Zueger T, Diem P, Mougiakakou S. Carbohydrate estimation supported by the GoCARB system in individuals with type 1 diabetes: A randomized prospective pilot study. *Diabet. Care*, 2017; 40: 106-107.
- Baranowski T, Baranowski JRD, Thompson D, Buday R, Jago R, Juliano M, Watson B. Video game play, child diet, and physical activity behavior change a randomized clinical trial. *Am J Prev Med*, 2011; 40(1): 33–38.
- Barrera CM, Hamner CH, Perrine CG, Scanlon KS. timing of introduction of complementary foods to us infants, national health and nutrition examination survey 2009-2014. *J Acad Nutr Diet*, 2018; 118(3): 464-470.
- Benton PM, Skouteris H, Hayden M. Does maternal psychopathology increase the risk of pre-schooler obesity? A systematic review. *Appetite*, 2015; 87: 259-82.
- Brown CL, Halvorson E, Cohen GM, Lazorick S, Skelton JA. Addressing childhood obesity opportunities for prevention. *Pediatr Clin North Am*, 2015; 62(5): 1241-61.
- Bulut F. Örnek tabanlı sınıflandırıcı topluluklarıyla yeni bir klinik karar destek sistemi. *Journal of the Faculty of Engineering and Architecture of Gazi University* 2017; 3(1): 65-76.

- Caferoğlu Z, Hatipoğlu N, Özel GH. Çocukluk Çağı Obezitesi ve Tedavi Yaklaşımları, İçinde: Tayfur M, editör. Beslenme ve Diyetetik Güncel Konular- V. (1. Baskı). Hatipoğlu Yayınları, Ankara, 2017; ss 27-58.
- Can, ÖY. Makine Öğrenmesi Teknikleri Kullanılarak Kredi Risk Analizi. Yüksek Lisans Tezi, İstanbul Aydın Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul 2020; ss 43-62.
- Canadian Pediatric Endocrine Group 2018. Erişim: [<https://cpeg-gcep.net/>], Erişim Tarihi: 12.02.2022.
- Cengiz A. Hasta teşhis koyma yardımcısı. Journal of ESTUDAM Information, 2020; 1(2): 6-9.
- Chollet F. Deep Learning with Python (2nd ed). Manning Publications Co, 2017; 56-78.
- Cleland VJ, Schmidt MD, Dwyer T. television viewing and abdominal obesity in young adults: is the association mediated by food and beverage consumption during viewing time or reduced leisure- time physical activity? Am.J.Clin.Nutr, 2008; 87: 1148-1155.
- Clemente MG, Mandato C, Poeta M, Vajro P. Pediatric non-alcoholic fatty liver disease: recent solutions, unresolved issues, and future research directions. World J Gastroenterol, 2016; 22(36): 78-93.
- Clifton PM, Chan L, Moss CL. Beverage intake and obesity in australian children, Nutr Metab, 2011; 1: 8-87.
- Correia-Costa L, Azevedo A, Caldas A. Childhood obesity and impact on the kidney. Nephron, 2018; 25: 1-4.
- Corsica JA, Hood MM. Eating disorders in an obesogenic environment. J Am Diet Assoc, 2011; 111: 996-1000.
- Coşkun S, Kartal M, Coşkun A, Bircan, H. Lojistik regresyon analizinin incelenmesi ve dış hekimliğinde bir uygulaması. Cumhuriyet Üniversitesi Dış Hekimliği Fakültesi Dergisi, 2004; 7(1), 41-50.
- Council on Communications and Media. Policy statement- children, adolescents, obesity, and the media. American Academic of Pediatrics, 2011; 128(1): 8-201.
- Çatlı G, Büyükgebiz A. Çocuk ve ergenlerde obezite: tanım ve epidemiyoloji. Türkiye Klinikleri J Pediatr Sci, 2015; 11(3): 7-21.
- Çebi S. Aksiyomlarla Tasarım Esaslı Bulanık Karar Destek Sistemi Geliştirme Ve Bir Uygulama, Doktora Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 2010; ss 5-72.
- Çelik N, Cinaz P. Obezitenin diğer komplikasyonları. Türkiye Klinikleri J Pediatr Sci, 2015; 11(3): 69-75.
- Çobanoğlu B. Herkes İçin Phyton. Pusula 20 Teknoloji ve Yayıncılık A.Ş. İstanbul 2021; ss 12-51.
- De Onis M, Blössner M, Borghi E. Global prevalence and trends of overweight and obesity among preschool children. Am J Clin Nutr, 2010; 92(5):1257-1264.
- Deboer M, Scharf R, Demmer R, Sugar-Sweetened Beverages and Weight Gain in 2- to 5-Year-Old Children, Pediatrics, 2013; 132: 413–420.

- Decelis A, Jago R, Fox K. Physical activity, screen time and obesity status in an nationally representative sample of maltese youth with international comparisons, BMC Public Health, 2014; 14: 664-668.
- Demolli H, Ecemiş A, Dokuz AŞ, Gökçek M. Makine öğrenmesi algoritmalarıyla güneş enerjisi tahmini: Niğde ili örneği. International Turkic World Congress on Science and Engineering, 2019; 1: 775-783.
- Dev DA, McBride BA, Fiese BH, Jones BL, Cho H; Behalf Of The Strong Kids Research Team. Risk Factors For Overweight/Obesity İn Preschool Children: An Ecological Approach. Child Obes, 2013; 9(5): 399-408.
- DSÖ Avrupa Bölgesi İçin Fiziksel Aktivite Stratejisi 2016-2025. DSÖ Avrupa Bölge Ofisi Yayınları, Kopenhag 2013; pp 5-23.
- Ergün U. The classification of obesity disease in logistic regression and neural network methods. J Med Syst, 2009; 33: 67–72.
- Erickson BJ, Korfiatis P, Akkus Z, Kline TL. Machine learning for medical imaging. Radiographics, 2017; 37(2): 505- 515.
- Estrada E, Eneli I, Hampl S, Mietus-Snyder M, Mirza N, Rhodes E. Children's hospital association consensus statements for comorbidities of childhood obesity. Child Obes, 2014; 10(4): 304-17.
- Eymen E. SPSS 15.0 Veri Analiz Yöntemleri. İstatistik Merkezi (e-kitap). https://yunus.hacettepe.edu.tr/~tonta/courses/spring2009/bby606/SPSS_15.0_ile_Veri_Analizi.pdf Erişim Tarihi: 10.08.22.
- Fatima M. ve Pasha M. Survey of machine learning algorithms for disease diagnostic. Journal of intelligent Learning Systems and Applications, 2017; 9: 1-16.
- Fulton JE, Dai S, Steffen LM, Grunbaum JA, physical activity, energy intake, sedentary behavior, and adiposity in youth, Am J Prev Med, 2009; 32: 40-49.
- García Castillo S, Hoyos Vázquez MDPS, Coloma Navarro R, Cruz Ruiz J, Callejas González FJ, Godoy Mayoral R. Obstructive sleep apnoea syndrome. An Pediatr (Barc), 2018; 88(5): 266-272.
- Garcia MB, Mangaba JB, Tanchoco CC. Virtual Dietitian: A Nutrition Knowledge-Based System Using Forward Chaining Algorithm, 2021 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT), 29-30 Eylül 2021; ss 309-314.
- Gauthier KI, Krajicek MJ. Obesogenic environment: a concept analysis and pediatri perspective. J Spec Pediatr Nurs, 2013; 18: 202– 210.
- Gentner D, Stelzer B, Ramosaj B, Brecht L. Strategic foresight of future b2b customer opportunities through machine learning. Technology Innovation Management Review, 2018; 8(10): 56-178.
- Göker H. Makine Öğrenmesi Teknikleri Kullanılarak Çocukluk Çağı Dikkat Eksikliği ve Hiperaktivite Bozukluğunun Tahmin Edilmesine Yönelik Uzman Sistem Tasarımı, Doktora Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara 2019; ss 5-78.
- Grant-Guimaraes J, Feinstein R, Laber E, Kosoy J. Childhood overweight and obesity. Gastroenterol Clin North Am, 2016; 45(4): 715-728.

- Greydanus DE, Agana M, Kamboj MK, Shebrain S, Soares N, Eke R. Pediatric obesity: Current concepts. *Dis Mon.* Apr, 2018; 64(4): 98-156.
- Guido van Rossum. 1990. Python. 3.9.4 sürümü. Hollanda
- Gurnani M, Birken C, Hamilton J. Childhood obesity: Causes, consequences, and management. *Pediatr Clin North Am*, 2015; 62(4): 821-840.
- Gustafson T, Sarwer D. Childhood sexual abuse and obesity. *Obes Rev*, 2004; 129-135.
- Güner N, Çomak E. Mühendislik öğrencilerinin matematik derslerindeki başarısının destek vektör makineleri kullanılarak tahmin edilmesi. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 2011; 17(2): 87–96.
- Hammond R, Athanasiadou R, Curado S, Aphinyanaphongs Y, Abrams C, Messito M.J, Gross R, Katzow M, Jay M, Razavian N, Elbel B. Predicting childhood obesity using electronic health records and publicly available data, *PloS One*, 2019; 14(4): 45-49.
- Hatipoğlu N, Mazicioglu MM, Poyrazoglu S, Borlu A, Horoz D, Kurtoglu S. Waist circumference percentiles among Turkish children under the age of 6 years. *Eur J Pediatr*, 2013; 172(1); 59–69.
- Hawkins MA, Stewart JC. Do negative emotional factors have independent associations with excess adiposity? *J Psychosomatic Res*, 2012; 243-250.
- Haykin, S. *Neural Networks A Comprarision Foundation* (2 nd ed). Pearson Education, London 1999; pp 19-48.
- Heroku. [<https://tr.wikipedia.org/wiki/Heroku>] Erişim Tarihi: 04 Mart 2022).
- Heydari ST, Ayatollahi SMT, Zare N. Comparison of artificial neural networks with logistic regression for detection of obesity, *Journal of medical systems*, 2012; 36 (4): 2449-2454.
- Horzum MB, Ayas T, Balta ÖÇ. Çocuklar İçin Bilgisayar Oyun Bağımlılığı Ölçeği, *Türk PDR Dergisi*, 2008; 30(3): 76-88.
- HSGM, Halk Sağlığı Genel Müdürlüğü. Çocukluk Çağı Obezitesinin Önlenmesi ile İlgili Eylem Planı 2019 – 2023. 2019. [https://hsgm.saglik.gov.tr/depo/birimler/saglikli-beslenme-hareketli-hayat-db/TSBHHP_2019-2023_Cocukluk_Cagi/Cocuk_Eylem_Plani_2019-16.12.2019.pdf], Erişim Tarihi: 13 Mart 2022.
- Huber S, Wiemer H, Schneider D, Ihlenfeldt S. DMME: Data mining methodology for engineering applications—a holistic extension to the CRISP-DM model. *Procedia CIRP*, 2019; 79: 403-408.
- Huh SY, Rifas-Shiman SL, Taveras EM, Oken E, Gillman MW. Timing of solid food introduction and risk of obesity in preschoolaged children. *Pediatrics*, 2011; 127(3): 544-551.
- Işgın K, Demirel BZ, Obezitenin Tedavisinde Nutrigenetik Yaklaşım, İçinde: Tayfur M, editör. *Beslenme ve Diyetetik Güncel Konular- V.* (1. Baskı). Hatipoğlu Yayınları, Ankara 2017; ss 111-132.

- Ileri YY, Hacıbeyoğlu M. Advancing competitive position in healthcare: a hybrid metaheuristic nutrition decision support system. *International Journal of Machine Learning and Cybernetics*, 2019; 10: 1385–1398.
- Jackson P, Romo MM, Castillo A, Castillo-Durán C. Junk food consumption and child nutrition. *Nutritional anthropological analysis*. *Rev Med Chil*, 2004; 132: 1235-1242.
- Jacquier EF, Deming DM, Eldridge AL. Location influences snacking behavior of US infants, toddlers and preschool children. *BMC Public Health*, 2018; 13: 18(1): 725-729.
- Kaisari P, Yannakoulia M, Panagiotakos DB. Eating frequency and overweight and obesity in children and adolescents: a meta-analysis. *Pediatrics*, 2013; 131(5): 958-967.
- Karaçıl MŞ, Şanlıer N. Obezitenin çevre ve sağlık üzerine etkileri. *Gümüşhane Üniversitesi Sağlık Bilimleri Dergisi*, 2014; 3(2):786-803.
- Kartal E. Sınıflandırmaya Dayalı Makine Öğrenmesi Teknikleri ve Kardiyolojik Risk Değerlendirmesine İlişkin Bir Uygulama. *Doktora Tezi, İstanbul Üniversitesi Fen Bilimleri Enstitüsü, İstanbul 2015; ss 11-67.*
- Kavuncu SK. Makine Öğrenmesi ve Derin Öğrenme: Nesne Tanıma Uygulaması Yüksek Lisans Tezi, Kırıkkale Üniversitesi Fen Bilimler Enstitüsü, Kırıkkale 2018; ss 30-78.
- Keel PK, Klump KL. Are Eating Disorders Culture-Bound Syndromes? Implications For Conceptualizing Their Etiology. *Psychological Bulletin*, 2003; 747-748.
- Keskin MV. Büyük Veride Makine Öğrenmesi Uygulaması. Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimler Enstitüsü, İstanbul 2018; ss 34-89.
- Kılınç M, Tarhan Ç, Aydın C. Makine öğrenmesi ve iş zekâsı yöntemleriyle mobil uygulama geliştiriciler için web platformu tasarlanması. 6. International Management Information Systems Conference “Connectedness And Cybersecurity”, İstanbul 9-12 Kasım 2019, ss 250-252.
- Kim C, Costello FJ, Lee KC, Li Y, Li C. Predicting Factors Affecting Adolescent Obesity Using General Bayesian Network and What-If Analysis. *Int Environ Res Public Health*, 2019;16(23): 45-49.
- Koçak B, Durmaz EŞ, Ateş E, Kılıçkesmez Ö. Radiomics with artificial intelligence: a practical guide for beginners. *Diagn Interv Radiol*, 2019; 25(6): 485- 495.
- Koletzko B, von Kries R, Closa R, Escubano J, Scaglioni S, Giovannini M, et al. Lower protein in infant formula is associated with lower weight up to age 2 y: A randomized clinical trial. *Am J Clin Nutr*, 2009; 89(6): 1836–1845.
- Komesli M. Coğrafi Bilgi Sistemlerinin OWL ve GML kullanılarak Anlamsal Web ile bütünleştirilmesi, Doktora Tezi, Ege Üniversitesi Fen Bilimleri Enstitüsü, İzmir, 2007; ss 56-120.
- Köksal E, Karaçıl MŞ. Okul Çağı Çocuklarında Şeker Tüketiminin Beden Kütle İndeksine Etkisinin Değerlendirilmesi. *Firat Med J*, 2014; 19(3): 151-155.
- Kundakçı AH. Üniversite Öğrencilerinin Yeme Tutumları, Benlik Algısı, Vücut Algısı ve Stres Belirtileri Açısından Karşılaştırılması, Yüksek Lisans Tezi. Ankara Üniversitesi Sosyal Bilimler Enstitüsü, Ankara 2005; ss 21-98.

- Kutlugün MA. Gözetimli Makine Öğrenmesi Yoluyla Türe Göre Metinden Ses Sentezleme. Yüksek Lisans Tezi, İstanbul Sabahattin Zaim Üniversitesi Fen Bilimler Enstitüsü İstanbul 2017; ss 45-67.
- Lantz B. Machine Learning with R (2 nd. ed). Packt Publishing Ltd. Birmingham 2013; pp 56-89.
- Linoff GS, Berry MJA. Data Mining Techniques: For Marketing, Sales, And Customer Relationship Management (2 nd ed). Wiley Publishing. Indianapolis 2004; pp 220-389.
- Loh WY. Classification and regression trees. WIREs Data Mining and Knowledge Discovery, 2011; 1(1): 14–23.
- Mameli C, Mazzantini S, Zuccotti GV. Nutrition in the first 1000 days: The origin of childhood obesity. Int. J. Environ. Res. Public Health, 2016; 23;13(9).
- Manios Y, Androutsos O, Katsarou C, Vampouli EA, Kulaga Z, Gurzkowska B, et al. Prevalence and sociodemographic correlates of overweight and obesity in a large Pan-European cohort of preschool children and their families: The ToyBox study. Nutrition, 2018; 192-198.
- Marakas GM. Modern Data Warehousing, Mining, and Visualization: Core Concepts. Prentice Hall, New Jersey 2003; pp 220-252.
- Mazzei A, Anselma L, De Michieli F, Bolioli A, Casu M, Gerbrandy J, Lunardi I. Mobile computing and artificial intelligence for diet management. Lect Notes Comput Sci, 2015; 9281: 342–349.
- McCarthy J. A proposal for the dartmouth summer research project on artificial intelligence, AI magazine, 2006; 27(4): 12-13.
- Microsoft Visual Studio, 2010, Visual Studio Code. Visual Studio 2022. USA
- Millar L, Rowland B, Nichols B, Swinburn B, Bennett C, Skouteris H, Allender S. Relationship between raised bmi and sugar sweetened beverage and high fat food consumption among children. Obesity, 2014; 1-22.
- Mozaffarian D, Hao T, Rimm EB. Changes in diet and lifestyle and long-term weight gain in women and men. N Engl J Med, 2011; 364: 2392–2404.
- Murdoch TB, Detsky AS. The inevitable application of big data to health care. Jama, 2013; 309(13): 1351-1352.
- Murphy KP. Machine Learning A Probabilistic Perspective. (1 nd ed). MIT Press, London 2012; pp 278-321.
- Musaiger AO, Al-Manni M, Al- Marzog Q. Overweight and obesity among children (10- 13 years) in bahrain: A comparison between two international standards, Pak J Med 2014; 30(3) 26-32.
- Mutlu AA. Epigenetik: Fetal beslenme ve erişkin çağı hastalıkları. Türkiye Klinikleri J Nutr Diet-Special Topics, 2015; 1(1): 15-19.
- Nathan BM, Noran A. Çocukluk Çağı ve Ergenlikteki obezitenin metabolik komplikasyonları: Diyabetten daha fazlası. Türkiye Klinikleri J Endocrin, 2009; 4(2): 68-77.

- Neyzi O, Günöz H, Furman A, Bundak R, Gökçay G, Darendeliler F, Baş F. Türk çocuklarında vücut ağırlığı, boy uzunluğu, baş çevresi ve vücut kitle indeksi referans değerleri. *Çocuk Sağlığı ve Hastalıkları Dergisi*, 2008; 51: 1-14.
- Noğay N., Köksal G, Çocuklarda metabolik sendromun tedavisinde beslenme yönetimi, *Güncel Pediatri*, 2012; 10: 92-97.
- Okur, H. Makine Öğrenmesi Yöntemleriyle Kredi Riski Tahmini Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara 2020; ss 2-45.
- Ong KK, Emmett PM, Noble S, Ness A, Dunger DB; ALSPAC Study Team. Dietary energy intake at the age of 4 months predicts postnatal weight gain and childhood body mass index. *Pediatrics*, 2006; 117(3): 503-508.
- Ortega FB, Ruiz JR. Physical activity, overweight and central adiposity in swedish children and adolescents, The european youth heart study, *Int.J.Behav.Nutr.Phys. Act*, 2007; 61(4): 23-28.
- Ortega-García JA, Kloosterman N, Alvarez L, Tobarra-Sánchez E, CárcelesÁlvarez A, Pastor-Valero R. Full breastfeeding and obesity in children: A prospective study from birth to 6 years. *Child Obes*, 2018; 14(5): 327- 337.
- Özata M, Aslan Ş. Klinik karar destek sistemleri ve örnek uygulamalar. *Kocatepe Tıp Dergisi*, 2004; 5: 11–17.
- Özçift A. Forward stage-wise ensemble regression algorithm to improve base regressors prediction ability: an empirical study. *Experts Systems*, 2014; 31(1): 1-8.
- Özkan, Y. Veri Madenciliği Yöntemleri (3.baskı). Papatya Yayıncılık, İstanbul 2008; ss 4-67.
- Öztemel E. Yapay Sinir Ağları (3.baskı). Papatya Yayıncılık, İstanbul 2012; ss 45-52.
- Öztürk A, Borlu A, Çiçek B, Altunay C, Ünala D, Hororz D, Balcı E, Üstünbaş HB, Bayat M, Mazıcıoğlu MM, Hatipoğlu N, Kurtoğlu S, Kesim S, Şenol V. 0-18 Yaş Çocuk ve Adolesanlarda Büyüme Eğrileri. *Türk Aile Hek Derg*. 2011; 15(3): 112-129.
- Pan L, Li X, Feng Y, Hong L. Psychological assessment of children and adolescents with obesity. *J Int Med Res*. 2018; 46(1): 89-97.
- Pearce J, Taylor MA, Langley-Evans SC. Timing of the introduction of complementary feeding and risk of childhood obesity: a systematic review. *Int J Obes*, 2013; 37(10): 1295-306.
- Pekcan G, Çocuk ve Ergenlerde Şişmanlığın Etiyolojisi, Çocuk ve Ergenlerde Ağırlık Yönetimi, 2011; 19-23.
- Petot GJ, Marling C, Sterling L. An artificial intelligence system for computer-assisted menü planning. *J Am Diet Assoc*, 1998; 98: 1009-1014.
- Pirgon MÖ. Çocukluk çağı obezitesinde çevresel faktörlerin rolü. *Türkiye Klinikleri J Pediatri Sci*, 2015; 11 (3): 8-22.
- Powers DMW: Evaluation: From precision, recall and f-measure to roc informedness, markedness & correlation. *Journal of Machine Learning Technologies*, 2011; 2 (1): 37-63.

- Pratt JSA, Browne A, Browne NT, Bruzoni M, Cohen M, Desai A, et al. ASMBS pediatric metabolic and bariatric surgery guidelines 2018. *Surg Obes Relat Dis*, 2018; 14(7): 882-901.
- Pulgaron ER, İ Childhood Obesity; A review of increased risk for physical and psychological comorbidities. *Clin. Ther.* 2013; 35: 18-32.
- Pulgaron ER, İ Childhood Obesity; A Review of Increased Risk for Physical and Psychological Comorbidities. *Clin. Ther.* 2013; 35: 18-32.
- Rhyner D, Lohrer H, Dehais J, Anthimopoulos M, Shevchik S, Botwey R.H, Duke D, Stettler C, Diem P, Mougiakakou S. Carbohydrate estimation by a mobile phone-based system versus self-estimations of individuals with type 1 diabetes mellitus: A comparative study. *J. Med. Internet Res*, 2016; 18: 101-108.
- Robinson SM, Crozier SR, Harvey NC, Barton BD, Law CM, Godfrey KM. Modifiable early-life risk factors for childhood adiposity and overweight: an analysis of their combined impact and potential for prevention. *Am J Clin Nutr*, 2015; 101(2):368-75.
- Rokach, L. ve Maimon O. Data mining with decision trees: theory and applications (69 nd. ed). World Scientific Publishing Co. Los Angeles 2008; pp 89-98.
- Ronacher A. Flask kütüphanesi [[https://en.wikipedia.org/wiki/Flask_\(web_framework\)](https://en.wikipedia.org/wiki/Flask_(web_framework))] (Erişim Tarihi 10 Mart 2022).
- Ruyter J, Olthof M, Seidell J, Katan M. A trial of sugar-free or sugar sweetened beverages and body weight in children. *N Eng J Med*, 2012; 367: 1397– 1406.
- Salehiniya H, Yazdani K, Barekati H, Asadi Lari M. The prevalence of overweight and obesity in children under 5 years in Tehran, Iran, in 2012: A population-based study. *Res Cardiovasc Med*, 2016; 5(1): 23-28.
- Salekin A, Stankovic J. Detection of chronic kidney disease and selecting important predictive attributes. International Conference on Healthcare Informatics (ICHI), Chicago 4-7 Ekin 2016; pp 262-270.
- Savino A, Pelliccia P, Chiarelli F, Mohn A. Obesity-related renal injury in childhood. *Horm Res Paediatr.*2010; 73(5): 303-311.
- Selimoğlu MA. Sağlıkta ve Hastalıkta Çocuk Beslenmesi (1. Baskı), Akademi Yayınevi, Ankara 2014; ss 189-195.
- Seth A, Sharma R. Childhood obesity. *Indian J Pediatr*, 2013; 80(4): 309-317.
- Shashaj B, Graziani MP, Contoli B, Ciuffo C, Cives C, Facciolini S. Energy balance-related behaviors, perinatal, sociodemographic, and parental risk factors associated with obesity in italian preschoolers. *J Am Coll Nutr*, 2016; 35(4): 362-371.
- Shearer C. The CRISP-DM model: the new blueprint for data mining, *Journal of data warehousing*, 2000; 5 (4), 13–22.
- Silahtaroglu G. Veri Madenciliği Kavram ve Algoritmaları (2.basım). Papatya Yayıncılık, İstanbul 2008; ss 58-73.
- Simmonds M, Llewellyn A, Owen CG, Woolacott N. Predicting Adult Obesity From Childhood Obesity: A Systematic Review and Meta-Analysis. *Obes Rev.*2016; 17(2): 95-107.

- Skinner AC, Perrin EM, Moss LA, Skelton JA. Cardiometabolic risks and severity of obesity in children and young adults. *N Engl J Med*. 2015; 373(14): 1307-17.
- Spear B, Barlow SE, Ervin C, Ludwig DS, Saelens BE. Recommendations for treatment of child and adolescent overweight and obesity. *Pediatrics*, 2007; 120; 254-289.
- SPSS Inc. 1968. SPSS. IBM SPSS Statistic 22.0. İngiltere
- Styne D, Arslanian S, Connor EL, Farooqi IS, Murad MH, Silverstein JH, et al. Pediatric obesity- assessment, treatment, and prevention: an endocrine society clinical practice guideline. *J Clin Endocrinol Metab*, 2017; 102(3): 709–57.
- Suglia SF, Duarte CS, Chambers EC, Boynton-Jarrett R. Cumulative social risk and obesity in early childhood. *Pediatrics*, 2012; 129(5): 1173-1179.
- Şahinarslan FV. Makine Öğrenmesi Algoritmaları ile Nüfus Tahmini: Türkiye Örneği. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul 2019; ss 12-67.
- Şeker S E. İş Zekâsı ve Veri Madenciliği. (1. Baskı) . Cinius Yayınları, İstanbul 2013; ss 67-89.
- Tabachnick BG, Fidell LS. Using multivariate statistics (6th ed.), Boston: Allyn and Bacon, 2013; 23-29.
- Tang A. Canadian association of radiologists white paper on artificial intelligence in radiology. *Canadian Association of Radiologists Journal*, 2018; 69(2): 120-135.
- Tian-en, C, Li-ping C, Yunbin G, Yanji W. Spatial decision support system for precision farming based on gis web service, *International Forum on Information Technology and Applications*, Chengdu 15-17 Mayıs 2009; ss 372-376.
- Toğaçar M, Ergen B. Biyomedikal görüntülerde derin öğrenme ile mevcut yöntemlerin kıyaslanması. *Fırat Üniversitesi Müh. Bil. Dergisi*, 2019; 31(1): 109-121.
- Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. *Nat Med*, 2019; 25(1): 44-56.
- Toschke AM, Küchenhoff H, Koletzko B, von Kries R. Meal frequency and childhood obesity. *Obes Res*, 2005; 13(11): 1932-1938.
- Towner EK, Clifford LM, McCullough MB, Stough CO, Stark LJ. Treating obesity in preschoolers: a review and recommendations for addressing critical gaps. *Pediatr Clin North Am*, 2016; 63(3): 481-510.
- TÜBER, Türkiye Beslenme Rehberi 2015. TC. Sağlık Bakanlığı. [<https://dosyasb.saglik.gov.tr/Eklenti/10915,tuber-turkiye-beslenme-rehberipdf.pdf>] Erişim Tarihi: 06 Mayıs 2020.
- Turunç Ö. Bilgi Teknolojileri Kullanımının İşletmelerin Örgütsel Performansına Etkisi. Doktora Tezi, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, Isparta 2006; ss 24-89.
- Türkiye Beslenme ve Sağlık Araştırması Beslenme Durumu ve Alışkanlıklarının Değerlendirilmesi Sonuç Raporu, Sağlık Bakanlığı, Hacettepe Üniversitesi, Sağlık Bilimleri Fakültesi, Beslenme ve Diyetetik Bölümü Ankara, 2019; ss 12-27.

- Uğur A. ve Kınacı AC. Yapay zekâ teknikleri ve yapay sinir ağları kullanılarak web sayfalarının sınıflandırılması. XI. Türkiye'de İnternet Konferansı (inet-tr'06) Ankara 21-23 Aralık 2006; ss 345-349.
- Uzun E. İnternet Tabanlı Bilgi Erişimi Destekli Bir Otomatik Öğrenme Sistemi, Doktora Tezi, Trakya Üniversitesi Fen Bilimleri Enstitüsü, Edirne 2007; ss 21-67.
- Ünsal Ö. Mesleki Alan Seçimlerinin Makine Öğrenmesi Algoritması Kullanılarak Belirlenmesi, Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara 2011; ss 32-69.
- Vandewater EA, Cummings H. Media Use and Childhood Obesity. In: S. L. Calvert & B. J. Wilson (Eds.), Handbook of Children, Media, and Development. Boston, MA: Wiley-Blackwell 2008; pp 355–380.
- Vasiloglou MF, Mougiakakou S, Aubry E, Bokelmann A, Fricker R, Gomes F, Guntermann C, Meyer A, Studerus D, Stanga Z. A Comparative study on carbohydrate estimation: GoCARB vs. Dietitians, Nutrients, 2018; 10(6): 741-743.
- Vehapoglu A, Goknar N, Turel O, Torun E, Ozgurhan. Risk factors for childhood obesity: Do the birth weight, type of delivery, and mother's overweight have an implication on current weight status? World J Pediatr, 2017; 13(5): 457-464.
- Viner RM, Cole TJ. Television viewing in early childhood predicts adult body mass index. J Pediatr, 2005; 147(4): 429-435.
- Waikato Üniversitesi, 2014.WEKA. 3.6.12 Sürümü. Yeni Zellanda.
- Wang Y. Global Perspectives of Childhood Obesity Prevalence, Contributing Factors, and Prevention. In: Goran MI, editors. Childhood Obesity: Causes, Consequences and Intervention Approaches. Taylor & Francis Group, 2017; pp 23-34
- Warkentin S, Mais LA, Latorre MDRDO, Carnell S, Taddei JAAC. Parents matter: associations of parental BMI and feeding behaviors with child BMI in Brazilian preschool and school-aged children. Front Nutr, 2018; 10;5: 69-75.
- WHO. United Nations Children's Fund. World Health Organization, International Bank for Reconstruction and Development/The World Bank. Levels and trends in child malnutrition: key findings of the 2018 Edition of the Joint Child Malnutrition Estimates. Geneva 2018; pp 1-9..
- WHO. World Health Organization. Global Nutrition Targets 2025: Childhood overweight policy brief (WHO/NMH/NHD/14.6). Geneva 2014; pp 1-8.
- WHO. World Health Organization. Taking action on childhood obesity. World Obesity Report, Kopenhagen 2018; pp 28-42.
- Wiechmann P, Lora K, Branscum P, Fu J. identifying discriminative attributes to gain insights regarding child obesity in hispanic preschoolers using machine learning techniques 2017. International Conference on Tools with Artificial Intelligence, 2017; 2375-2497.
- Wijtzes AI, Jansen W, Bouthoorn SH, van Lenthe FJ, Franco OH, Hofman A, et al. Meal-Skipping Behaviors and Body Fat in 6-Year-Old Children. J Pediatr, 2016; 168: 118-125.

- Woo BJA, Locks LM, Cheng ER, Blake-Lamb TL, Perkins ME, Taveras EM. Risk factors for childhood obesity in the first 1,000 Days: A systematic review. *Am J Prev Med*, 2016; 50(6): 761-779.
- Wu RC, Chen RS, Chian SS. Design of a product quality control system based on the use of data mining techniques. *IIE Transactions*, 2006; 38(1): 39-51.
- Yabancı N, Kısaç İ, Karakuş SŞ. The effects of mother's nutritional knowledge on attitudes and behaviors of children about nutrition. *Procedia- Social and Behavioral Sciences*, 2014; 116: 4477-4481.
- Yan J, Liu L, Zhu Y, Huang G, Wang PP. The association between breastfeeding and childhood obesity: a meta-analysis. *BMC Public Health*, 2014; 14: 1617-1619.
- Yeşilnacar E ve Topal T. Landslide susceptibility mapping: A comparison of logistic regression and neural networks methods in a medium scale study. *Hendek Region (Turkey), Engineering Geology*, 2005; 79: 251-266.
- Yıldırım S. Yapay zekânın tüketim kültürü bağlamında değerlendirilmesi: black mirror örneği. *Abant Kültürel Araştırmalar Dergisi*, 2020; 31-43.
- Yılmaz, R. Türkçe Dökümanların Sınıflandırılması, Yüksek Lisans Tezi, Aydın Adnan Menderes Üniversitesi Fen Bilimleri Enstitüsü, Aydın 2013; ss 9-56.
- Yurtay Y, Yılmaz Z, Çiftçi Ö, Ayar K. Kadınlarda demir eksikliğine bağlı kansızlık tanısına ilişkin bir veri madenciliği çalışması. *International Science and Technology Conference*, Dubai 13-15 Aralık 2012; pp 45-46.
- Zhang S., Tjortjis C., Zeng X., Qiao H., Buchan I., Keane J. Comparing data mining methods with logistic regression in childhood obesity prediction. *Inf Syst Front* 2009; 11: 449-460.
- Zheng M, Rangan A, Olsen NJ, Andersen B, Wedderkopp N, Kristensen P. Sugar-sweetened beverages consumption in relation to changes in body fatness over 6 and 12 years among 9-year-old children: the european youth heart study, *European Journal of Clinical Nutrition*, 2014; 68: 77-83.

EKLER

Ek-1 ÇOCUKLARDA BEDEN KÜTLE İNDEKSİ PERSENTİL DEĞERLERİ (kg/m²)

Erkek							Yaş	Kız						
5	15	25	50	75	85	95		5	15	25	50	75	85	95
11.4	12.2	12.7	13.7	14.6	15.2	16.1	Doğum	11.4	12.2	12.6	13.5	14.4	14.9	15.8
14.4	15.3	15.8	16.9	18.0	18.6	19.7	3 ay	13.9	14.8	15.3	16.3	17.3	17.9	18.9
15.0	15.9	16.5	17.5	18.6	19.2	20.3	6 ay	14.7	15.4	15.9	16.9	18.0	18.6	19.7
15.1	16.0	16.5	17.5	18.6	19.3	20.4	9 ay	14.8	15.5	16.0	17.0	18.0	18.6	19.8
14.9	15.7	16.2	17.2	18.3	18.9	20.0	12 ay	14.6	15.3	15.7	16.6	17.7	18.2	19.4
14.7	15.5	16.0	17.0	18.0	18.6	19.7	15 ay	14.5	15.1	15.6	16.4	17.4	18.0	19.1
14.5	15.3	15.7	16.7	17.7	18.3	19.3	18 ay	14.2	14.9	15.3	16.2	17.1	17.7	18.8
14.3	15.0	15.4	16.3	17.3	17.9	19.0	2yaş	14.0	14.6	15.1	15.9	16.9	17.4	18.5
14.2	14.8	15.3	16.2	17.2	17.7	18.8	2.5yaş	13.9	14.6	15.0	15.8	16.7	17.3	18.3
13.9	14.6	15.0	15.9	17.0	17.6	18.7	3 yaş	13.8	14.4	14.8	15.5	16.4	17.0	17.9
13.8	14.5	14.9	15.8	16.8	17.4	18.5	3.5 yaş	13.7	14.3	14.7	15.5	16.4	17.0	18.0
13.7	14.4	14.8	15.7	16.7	17.3	18.4	4 yaş	13.6	14.2	14.6	15.4	16.4	17.0	18.1
13.6	14.2	14.7	15.6	16.6	17.2	18.4	4.5 yaş	13.5	14.2	14.6	15.4	16.5	17.1	18.2
13.5	14.2	14.6	15.5	16.5	17.1	18.3	5 yaş	13.4	14.1	14.5	15.4	16.5	17.2	18.5
13.4	14.1	14.5	15.4	16.5	17.1	18.4	5.5 yaş	13.4	14.0	14.5	15.5	16.6	17.3	18.8
13.4	14.1	14.5	15.4	16.5	17.2	18.5	6 yaş	13.3	14.0	14.5	15.5	16.7	17.5	19.1
13.6	14.3	14.7	15.7	16.9	17.6	19.1	7 yaş	13.3	14.0	14.5	15.6	16.9	17.8	19.7
13.8	14.5	15.0	16.1	17.4	18.2	19.9	8 yaş	13.4	14.2	14.7	15.9	17.4	18.4	20.4
14.0	14.8	15.3	16.5	18.0	19.0	21.0	9 yaş	13.6	14.5	15.1	16.4	18.1	19.2	21.5
14.1	15.1	15.7	17.1	18.9	20.1	22.5	10 yaş	13.9	14.9	15.6	17.1	19.0	20.2	22.6
14.6	15.8	16.5	18.2	20.4	21.7	24.5	11 yaş	14.5	15.6	16.4	18.0	20.0	21.3	23.8
15.2	16.5	17.4	19.3	21.7	23.1	26.0	12 yaş	15.3	16.5	17.3	19.0	21.1	22.3	24.8
15.6	17.0	18.0	19.9	22.3	23.7	26.5	13 yaş	16.3	17.5	18.3	19.9	21.9	23.1	25.4
16.4	17.7	18.6	20.5	22.8	24.2	27.0	14 yaş	17.1	18.3	19.0	20.6	22.5	23.6	25.8
17.2	18.5	19.4	21.2	23.4	24.8	27.6	15 yaş	17.7	18.8	19.5	21.0	22.8	23.9	26.0
18.0	19.3	20.1	21.9	24.1	25.4	28.2	16 yaş	18.1	19.1	19.8	21.2	23.0	24.0	26.1
18.7	19.9	20.7	22.5	24.7	26.1	28.8	17 yaş	18.5	19.5	20.1	21.5	23.1	24.2	26.2
19.2	20.5	21.3	23.1	25.2	26.6	29.4	18 yaş	19.0	19.9	20.5	21.8	23.3	24.3	26.1

Ek-2 ETİK KURUL ONAYI

ERCİYES ÜNİVERSİTESİ SOSYAL VE BEŞERİ BİLİMLER ETİK KURULU PROJE ONAY FORMU

BAŞVURU NO: 128

Projenin Adı	"Makine Öğrenmesi Algoritmaları İle Geliştirilen Erken Uyarı Sistemi İle Çocukluk Çağı Obezite Riskinin Saptanması"
Projenin Niteliği	Yüksek Lisans/Uzmanlık/Doktora Tezi
Proje Araştırmacıları	Burcu ÇAVDAR (Sorumlu Araştırmacı) Betül ÇİÇEK (Danışman)
Sorumlu Araştırmacının Haberleşme Bilgileri	Burcu ÇAVDAR (Sorumlu Araştırmacı) Betül ÇİÇEK (Danışman) Tokat İl Sağlık Müdürlüğü Halk Sağlığı Başkanlığı (Hoca Ahmet Mah. Mesrur Gürgeç Cad. No:4 TOKAT) Kat:4 60100 TOKAT/Merkez E-posta adresi: bureucavdr@gmail.com

KARAR:

Etik Kurulumuza başvuran **Burcu ÇAVDAR**'ın "**Makine Öğrenmesi Algoritmaları İle Geliştirilen Erken Uyarı Sistemi İle Çocukluk Çağı Obezite Riskinin Saptanması**" adlı Çalışması değerlendirilerek aşağıdaki sonuca ulaşılmıştır.

- Proje etik açıdan uygun bulunmuştur. ☒
- Projenin etik açıdan geliştirilmesi gerekmektedir. ☐
- Proje etik açıdan uygun bulunmamıştır. ☐

28/08/2020

ADI SOYADI	
Etik Kurul Başkanı	Prof. Dr. Mustafa ARGUNŞAH
Etik Kurul Başkan Yrd.	Prof. Dr. Kasım KARAMAN
Üye	Prof. Dr. Celal YILDIZ
Üye	Prof. Dr. Mehmet AKKURT
Üye	Prof. Dr. Mustafa AKDAĞ
Üye	Prof. Dr. Mustafa DEMİRCİ
Üye (Raportör)	Prof. Dr. Handan ZİNCİR
Üye	Doç. Dr. Davut İLTAŞ
Üye	Doç. Dr. Burak ADIGÜZEL

Ek-3 TOKAT MİLLİ EĞİTİM MÜDÜRLÜĞÜ İZİN BELGESİ



T.C.
TOKAT VALİLİĞİ
İl Millî Eğitim Müdürlüğü

Sayı : 27001677-44-E.13826234
Konu : Araştırma İzni Verilmesi

30/09/2020

VALİLİK MAKAMINA

İlgi : a) Millî Eğitim Bakanlığına Bağlı Okul ve Kurumlarda Yapılacak Araştırma ve Araştırma Desteğine Yönelik İzni ve Uygulama Yönergesi.
b) 23/10/2019 tarihli ve 27001677/44/20812138 sayılı Valilik Makam Onayı.
c) Araştırma İzinleri İnceleme Komisyonunun 29.09.2020 tarihli tutanağı.
d) Erciyes Üniversitesi Rektörlüğü Öğrenci İşleri Daire Başkanlığının 22.09.2020 tarih ve 15151 sayılı yazısı.

Erciyes Üniversitesi'nin ilgi (d) talebi gereği Sağlık Bilimleri Enstitüsü Beslenme ve Diyetetik Anabilim Dalı doktora öğrencisi Burcu ÇAVDAR Müdürlüğümüze bağlı Özel Anasınıfı, Resmi Anasınıfı ve Resmi Bağımsız Anaokulları'nda öğrenci ve öğrenci velilerine yönelik "Makine Öğrenmesi Algoritmaları ile Geliştirilen Erken Uyarı Sistemi ile Çocukluk Çağı Obezite Riskinin Saptanması" başlıklı tez çalışmasını uygulamak istenmektedir.

Erciyes Üniversitesi Sağlık Bilimleri Enstitüsü Beslenme ve Diyetetik Anabilim Dalı doktora öğrencisi Burcu ÇAVDAR'ın hazırlamış olduğu "Makine Öğrenmesi Algoritmaları ile Geliştirilen Erken Uyarı Sistemi ile Çocukluk Çağı Obezite Riskinin Saptanması" konulu bilimsel amaçlı anket çalışmasını Müdürlüğümüze bağlı Özel Anasınıfı, Resmi Anasınıfı ve Resmi Bağımsız Anaokulları'nda öğrenci ve öğrenci velilerine yönelik uygulama yapılması Müdürlüğümüzce de uygun görülmektedir.

Makamınızca da uygun görüldüğü takdirde Olur'unuza arz ederim.

Murat KÜÇÜKALİ
İl Millî Eğitim Müdürü

OLUR
30/09/2020

Osman SARI
Vali a.
Vali Yardımcısı

Ek:
1-Tutanak
2-Erciyes Ün. Rektörlüğü yazısı ve Ekleri



Adres: GOP Bulvarı 60100 Tokat/Merkez
Elektronik Ad: www.meb.gov.tr
e-posta: stratejigelistirme60@meb.gov.tr

Bilgi için: Adnan YÜCE Memur
Tel: 0 (356) 214 10 17
Faks: 0 (356) 214 11 86

Bu evrak güvenli elektronik imza ile imzalanmıştır. <https://evrak.sorgu.meb.gov.tr> adresinden c5f3-3a97-377c-97bf-54ef kodu ile teyit edilebilir.

Ek-4 Çocukluk Çağı Obezite Riski ile İlişkili Risk Faktörleri Anket Formu

Bu anket, çocukluk çağında obezite riskini artıran obezogenik çevre ile alakalı soruları içermektedir. Anket sonuçlarına göre çocukların obezite riski değerlendirilecektir.

Anket katılımı gönüllülük esasına dayanmaktadır.

Anket No:

Tarih: ../../2020

A. Obezite Riski ile İlişkili Faktörler

- 1) Cinsiyet: 2) Yaş (yıl):
- 3) Vücut ağırlığı (kg)..... 4) Boy uzunluğu (cm):.....
- 5) Başınızdan sizi çok üzen bir olay geçti mi? a) Evet b) Hayır
- 6) Ailede hafif şişman - obez olan var mı? a) Evet b) Hayır
- 7) Aylık gelir durumunuz nedir?
a) Geliri giderinden az b) Geliri giderine eşit c) Geliri giderinden fazla
- 8) Anne Eğitim Durumu nedir?
a) ilköğretim b) lise c) önlisans d) lisans/lisansüstü
- 9) Annenin mesleği nedir?.....
- 10) Babanın mesleği nedir?.....

B. Günlük aktivite çizelgesi

1. Sportif ve bedensel aktivitelere ayrılan süre	a) 1 saatten az b) 1-2 saat c) 2 saatten fazla
2. Bilgisayar/tablet/cep telefonu karşısında geçirilen süre	a) 1 saatten az b) 1-2 saat c) 2 saatten fazla
3. Televizyon karşısında geçirilen süre	a) 1 saatten az b) 1-2 saat c) 2 saatten fazla

C. Günlük Öğün Tüketim Durumu

	Her gün	Arada bir	Hiç
1) Kahvaltı			
2) Öğle yemeği			
3) Akşam yemeği			
4) Kuşluk			
5) İkinci			
6) Yatsı			

D. Bazı Besinlerin Tüketim Sıklığı

	Her gün	Arada bir	Hiç
1) Süt ve süt ürünleri			
2) Et ve et ürünleri			
3) Tahıl ürünleri			
4) Meyve ve sebze			
5) Bal			
Tereyağı			
6) Fast-food			
Hamur işi			
Cips, patates kızartması			
Gazlı içecek- Hazır Meyve suyu			
Çikolata-Bisküvi-kraker vb.			

G. Yaşamın İlk 1000 Gününe Ait Faktörler

- 1) Maternal doğum haftası? a) 37. haftadan önce b) 37-40. hafta arası
c) 40. haftadan sonra
- 2) Çocuğun doğum ağırlığı? a) <2500 g b) 2500-4000 g c) >4000 g
- 5) Sadece (tek başına) anne sütü alma süresi? a) <6 ay b) >6 ay
- 6) Toplam anne sütü alma süresi? a) <12 ay b) >12 ay
- 7) Bebeklikte mama tüketme durumu? a) Tüketti b) Tüketmedi

Ek-5 AYRINTILI BİLGİLENDİRME FORMU

AYRINTILI BİLGİLENDİRME FORMU

Araştırmacının Açıklaması

Makine öğrenmesi yaklaşımları kullanılarak çocukluk çağı obezitesi sorununa erken teşhis konulmasını sağlamak amacıyla bir bilimsel araştırma yapmayı planlamaktayız. Yapılması planlan araştırmanın ismi “Makine Öğrenmesi Algoritmaları ile Geliştirilen Erken Uyarı Sistemi ile Çocukluk Çağı Obezite Riskinin Saptanması” dir.

Okul öncesi çağı çocukları üzerinde yapılacak olan bu çalışmaya, çocuğunuzun yaş grubu bu koşullara uyduğu için sizi de davet ediyoruz. Ancak hemen belirtilmelidir ki araştırmaya katılıp katılmamak gönüllülük esasına dayalıdır. Bu bilimsel çalışmaya katılma kararını tamamen hür iradeniz ile vermelisiniz. Bu kararı verirken hiç kimse tarafından size telkin ve baskıda bulunulamaz.

Kararınızdan önce söz konusu bilimsel araştırma ve bu araştırmaya katılmayı kabul etmeniz durumunda yapılacak işlemler hakkında sizi bilgilendirmek istiyoruz. Bu bilgileri okuyup anladıktan sonra bu bilimsel araştırmaya katılmak isterseniz formu imzalayınız.

Bilimsel çalışma hakkında bilgiler

Araştırmaya davet edilmenizin nedeni, çocuğunuzun 4-6 yaş aralığında olmasıdır.

Toplumumuzda beslenme alışkanlıkları gün geçtikçe farklılaşmaktadır. Yanlış beslenme alışkanlıkları özellikle okul öncesi çağındaki çocuklarda yaygınlaşmaktadır. Bu yanlış beslenme alışkanlıkları ve yaşam tarzı alışkanlıkları; yetişkinlik çağında obezite riskinin artmasına neden olmaktadır.

Çağımızın hızla artan problemi olan obezitenin ortaya çıkmadan saptanmasını sağlayacak uygulanabilir web tabanlı bir sistem geliştirip, okul öncesi eğitim kurumlarında çocukların bu sistemle düzenli olarak taranmasını sağlamak ve böylece çocukluk çağında obezite henüz gelişmeden önlem alınmasına katkı sağlanması amaçlanmıştır.

Çalışma kapsamında bilinmesi gereken durumlar ve araştırmacılar ile gönüllülerin uyması gereken kurallar

Araştırmaya katılmanız durumunda;

1. Sizden herhangi bir ücret istenmeyecektir.
2. Çalışmaya katıldığınız için size ek bir ödeme yapılmayacaktır.
3. Diyetisyen ile aranızda kalması gereken size ait bilgilerin gizliliğine büyük özen ve saygı gösterilecektir.
4. Araştırma sonuçlarının eğitim ve bilimsel amaçlarla kullanımı sırasında kişisel bilgileriniz çok büyük bir hassasiyetle korunacaktır.

5. Çalışma sırasında meydana gelebilecek sağlığınız ile ilgili ve diğer olumsuzlukların sorumluluğu araştırmacılara aittir.
6. Gönüllü olarak katıldığınız çalışmanın herhangi bir aşamasında araştırmadan ayrılabilirsiniz. Ancak ayrılmadan önce araştırmacılara bu durumu bildirmeniz önemlidir.
7. Çalışmaya katılmayı kabul etmemeniz durumunda tedavinizde ve klinik izlemlerinizde hiçbir değişiklik olmayacak, her zaman olduğu gibi aynı özen ve ihtimam ile hastalığınızın tedavisi sürdürülecektir.

Katılımcının (Gönüllü) / Hastanın Beyanı

Sayın Prof. Dr. Betül ÇİÇEK ve Dyt Burcu ÇAVDAR tarafından Beslenme ve Diyet Anabilim Dalında bir araştırma yapılacağı belirtilerek bu araştırma ile ilgili yukarıdaki bilgiler tarafıma aktarıldı. Bu bilgilerden sonra böyle bir araştırmaya “katılımcı” olarak davet edildim.

Eğer bu araştırmaya katılırsam, diyetisyen ile aramda kalması gereken, bana ait bilgilerin gizliliğine bu araştırma sırasında da büyük özen ve saygı gösterileceği, araştırma sonuçlarının eğitim ve bilimsel amaçlarla kullanımı sırasında kişisel bilgilerimin ihtimamla korunacağı kesin ve net bir şekilde belirtilmiştir.

Araştırma için yapılacak harcamalarla ilgili herhangi bir parasal sorumluluk altına girmiyorum. Benden herhangi bir ücret talep edilmeyeceği ve bana da herhangi bir ödeme yapılmayacağı net ve kesin bir şekilde ifade edilmiştir.

Projenin yürütülmesi sırasında herhangi bir sebep göstermeden araştırmadan çekilme hakkına sahip olduğum bildirilmiştir. Ancak araştırmacıları zor durumda bırakmamak için araştırmadan çekileceğimi önceden bildirmemin uygun olacağının da bilincindeyim. Ayrıca tıbbi durumuma herhangi bir zarar verilmemesi koşuluyla araştırmacı tarafından araştırma dışı tutulabilirim.

İster doğrudan, ister dolaylı olsun, araştırma sürecinde araştırma ile ilgili ortaya çıkabilecek sağlık durumuyla ilgili olumsuzluklarda sorumluluk araştırmacılara ait olup parasal bir yük altına girmeyeceğim.

Araştırma sırasında araştırma ile ilgili bir sağlık sorunu ile karşılaştığımda; günün herhangi bir saatinde Dyt. Burcu ÇAVDAR’a, numaralı telefonlardan ulaşarak danışabileceğimi biliyorum.

Bu araştırmaya katılmak zorunda değilim ve katılmayabilirim. Araştırmaya katılmam konusunda zorlayıcı herhangi bir davranışla karşılaşmış değilim. Eğer katılmayı reddedersem, bu durumun tıbbi bakımına ve hekim ile olan ilişkiye herhangi bir zarar getirmeyeceğini de biliyorum.

Bana yapılan tüm açıklamaları ayrıntılarıyla anlamış bulunmaktayım. Kendi başıma belli bir düşünme süresi sonunda adı geçen bu araştırma projesinde “katılımcı” (gönüllü) olarak yer alma kararını tamamen hür iradem ile almış bulunuyorum. Bu konuda yapılan daveti büyük bir memnuniyet ve gönüllük içerisinde kabul ediyorum.

İzole edilen genetik materyalinin gelecekteki bilimsel çalışmalarda da kullanılmasına onay

Katılımcı “.....” kısmı “**veriyorum**” ya da “**vermiyorum**” şeklinde kendisi, vasisi veya görüşme tanığının el yazısı ile yazılması suretiyle yanıtlayacak ve yanına paraf atılacaktır. Not; Çalışma gen polimorfizm çalışması değil ise bu kutuyu ve içindeki açıklamayı formu bastırmadan önce kaldırınız.

Tarih

Katılımcı (Gönüllü)

Adı, Soyadı :

Adres :

Telefon :

İmza :

Görüşme Tanığı

Adı, Soyadı :

Adres :

Telefon :

İmza :

Katılımcı (Gönüllü) ile Görüşen Araştırmacı

Adı, Soyadı, Ünvanı :

Adres :

Telefon :

İmza :

(Tüm sayfaları imzalı bu formun bir kopyası katılımcıya verilecektir)

Ek-6 ÇALIŞMA KATILIM KABUL FORMU

ÇALIŞMA KATILIM KABUL FORMU

Sayın Katılımcımız

Katılacağınız bu çalışma,” “Makine Öğrenmesi Algoritmaları ile Geliştirilen Erken Uyarı Sistemi ile Çocukluk Çağı Obezite Riskinin Saptanması”” adıyla, Burcu Çavdar tarafından Ekim 2020 / Mart 2021 tarihleri arasında yapılacak bir araştırma uygulamasıdır.

Araştırmanın Hedefi: Obezite ile mücadelede erken uyarı sistemi geliştirilmesi ile ilgili çalışmalar mevcuttur. Ancak, bunlar daha çok hangi makine öğrenmesi algoritmasının daha başarılı sonuç verdiğini araştırmaya yönelik mühendislik çalışmalarıdır. Çağımızın hızla artan problemi olan obezitenin ortaya çıkmadan saptanmasını sağlayacak uygulanabilir web tabanlı bir sistem geliştirip, okul öncesi eğitim kurumlarında çocukların bu sistemle düzenli olarak taranmasını sağlamak ve böylece çocukluk çağında obezite henüz gelişmeden önlem alınmasına katkı sağlanması amaçlanmıştır.

Araştırmanın Nedeni: O Tez çalışması

Araştırmanın Yapılacağı Yer(ler): Tokat Milli Eğitim Müdürlüğüne bağlı anaokulları

Araştırma Uygulaması: O Anket

O Görüşme

Araştırma T.C. Milli Eğitim Bakanlığı’nın ve okul/kurum yönetiminin izni ile gerçekleştirilmektedir. Araştırma uygulamasına katılım tamamıyla gönüllülük esasına dayalı olmaktadır. Çalışmada sizden kimlik belirleyici hiçbir bilgi istenmemektedir. Cevaplar tamamıyla gizli tutulacak ve sadece araştırmacılar tarafından değerlendirilecektir. Veriler sadece araştırmada kullanılacak ve üçüncü kişilerle paylaşılmayacaktır.

Uygulamalar, kişisel rahatsızlık verecek sorular ve durumlar içermemektedir. Ancak, katılım sırasında sorulardan ya da herhangi başka bir nedenden rahatsız hissederseniz cevaplama işini yarıda bırakabilirsiniz.

Katılımı onaylamadan önce sormak istediğiniz herhangi bir konu varsa sormaktan çekinmeyiniz. Çalışma bittikten sonra bizlere telefon veya e-posta ile ulaşarak soru sorabilir, sonuçlar hakkında bilgi isteyebilirsiniz. Saygılarımızla,

Araştırmacı :Burcu Çavdar

İletişim Bilgileri

Yukarıda bilgileri bulunan araştırmaya katılmayı kabul ediyorum.

.../.../.....

İsim-Soyisim İmza:

Katılımcı Adı-Soyadı :

Telefon Numarası :

Ek-7 VELİ ONAM FORMU

Veli Onam Formu

Sayın Veli;

Çocuğunuzun katılacağı bu çalışma, “Makine öğrenmesi algoritmaları ile geliştirilen erken uyarı sistemi ile çocukluk çağı obezite riskinin saptanması” adıyla, Ekim 2020 / Mart 2021 tarihleri arasında yapılacak bir araştırma uygulamasıdır.

Araştırmanın Hedefi: Obezite ile mücadelede erken uyarı sistemi geliştirilmesi ile ilgili çalışmalar mevcuttur. Ancak, bunlar daha çok hangi makine öğrenmesi algoritmasının daha başarılı sonuç verdiğini araştırmaya yönelik mühendislik çalışmalarıdır. Çağımızın hızla artan problemi olan obezitenin ortaya çıkmadan saptanmasını sağlayacak uygulanabilir web tabanlı bir sistem geliştirip, okul öncesi eğitim kurumlarında çocukların bu sistemle düzenli olarak taranmasını sağlamak ve böylece çocukluk çağında obezite henüz gelişmeden önlem alınmasına katkı sağlanması amaçlanmıştır.

Araştırma Uygulaması: Anket / Görüşme / Gözlem şeklindedir.

Araştırma T.C. Milli Eğitim Bakanlığı’nın ve okul yönetiminin de izni ile gerçekleştirilmektedir. Araştırma uygulamasına katılım tamamıyla gönüllülük esasına dayalı olmaktadır. Çocuğunuz çalışmaya katılıp katılmamakta özgürdür. Araştırma çocuğunuz için herhangi bir istenmeyen etki ya da risk taşımamaktadır. Çocuğunuzun katılımı **tamamen sizin isteğinize bağlıdır**, reddedebilir ya da herhangi bir aşamasında ayrılabilirsiniz. Araştırmaya katılmamama veya araştırmadan ayrılma durumunda öğrencilerin akademik başarıları, okul ve öğretmenleriyle olan ilişkileri etkilemeyecektir.

Çalışmada öğrencilerden kimlik belirleyici hiçbir bilgi istenmemektedir. Cevaplar tamamıyla gizli tutulacak ve sadece araştırmacılar tarafından değerlendirilecektir.

Uygulamalar, genel olarak kişisel rahatsızlık verecek sorular ve durumlar içermemektedir. Ancak, katılım sırasında sorulardan ya da herhangi başka bir nedenden çocuğunuz kendisini rahatsız hissederse cevaplama işini yarıda bırakıp çıkmakta özgürdür. Bu durumda rahatsızlığın giderilmesi için gereken yardım sağlanacaktır. Çocuğunuz çalışmaya katıldıktan sonra istediği an vazgeçebilir. Böyle bir durumda veri toplama aracını uygulayan kişiye, çalışmayı tamamlamayacağını söylemesi yeterli olacaktır. Anket çalışmasına katılmamak ya da katıldıktan sonra vazgeçmek çocuğunuza hiçbir sorumluluk getirmeyecektir.

Onay vermeden önce sormak istediğiniz herhangi bir konu varsa sormaktan çekinmeyiniz. Çalışma bittikten sonra bizlere telefon veya e-posta ile ulaşarak soru sorabilir, sonuçlar hakkında bilgi isteyebilirsiniz. Saygılarımızla,

Araştırmacı :Burcu Çavdar

İletişim Bilgileri :

Velisi bulunduğum sınıfı numaralı öğrencisi

.....

.....’in yukarıda açıklanan araştırmaya katılmasına izin veriyorum. (Lütfen formu imzaladıktan sonra çocuğunuzla okula geri gönderiniz*).

.... / /

Makine öğrenmesi algoritmaları ile geliştirilen erken uyarı sistemi ile çocukluk çağı obezitesinin saptanması

ORJİNALLİK RAPORU

% 13	% 12	% 3	% 6
BENZERLİK ENDEKSİ	İNTERNET KAYNAKLARI	YAYINLAR	ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1	acikerisim.medipol.edu.tr	% 3
2	acikbilim.yok.gov.tr	% 2
3	nek.istanbul.edu.tr:4444	% 1
4	i-rep.emu.edu.tr:8080	% 1
5	www.researchgate.net	% 1
6	www.openaccess.hacettepe.edu.tr:8080	% 1
7	BULUT, Faruk. "Örnek tabanlı sınıflandırıcı topluluklarıyla yeni bir klinik karar destek sistemi", Gazi Üniversitesi, 2017. Yayın	<% 1
8	dergipark.org.tr	<% 1

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Burcu ÇAVDAR
Uyruğu : Türkiye (T.C)

EĞİTİM

<u>DERECE</u>	<u>KURUM</u>	<u>MEZUNİYET</u>
Yüksek Lisans	Ondokuz Mayıs Üniversitesi /Beslenme ve Diyetetik	2016
Lisans	Ankara Üniversitesi/Beslenme ve Diyetetik	2011
Lise	Tokat Anadolu Öğretmen Lisesi	2007

İŞ DENEYİMLERİ

<u>YIL</u>	<u>KURUM</u>	<u>GÖREV</u>
2011-2013	Erzurum Bölge Eğitim ve Araştırma Hastanesi	Diyetisyen
2013-2015	Ordu Devlet Hastanesi	Diyetisyen
2015-2020	Tokat Devlet Hastanesi	Diyetisyen
2020- Halen	Tokat İl Sağlık Müdürlüğü	Diyetisyen

YAYINLAR:

Boyras Ö, Alataş H, Toğuş H, Delen L, Çavdar B, Nacar E, Yaprak B. The Effect of Mediterranean Diet Compliance on COVID-19 Symptoms and Disease Severity. J Mol Virol Immunol 2022; 3(3): 113-120.

ULUSAL VE ULUSLARARASI KONGRELERDEKİ POSTER BİLDİRİLER:

Adıgüzel E, Ün İ, Aytekin G, Çavdar B, Öksüzkaya F, Yılmaz M. Genç Yetişkin Bireylerin Yeme Tutum, Davranışları Ve Beslenme Alışkanlıkları. 1st International Health Science And Life Congress, 2018,(Sözlü Bildiri)

Fidan E, Çavdar B, Adıgüzel E. Multipl travmalı hastada beslenme durumunun düzenlenmesi: Olgu sunumu. 1. Uluslararası Palyatif Bakım Kongresi. 2019. (Sözlü Bildiri)

Fidan E, Çavdar B. Kakulenin Sağlık Üzerine Etkileri. 1. Uluslararası Palyatif Bakım Kongresi. 2019.(Poster Sunumu)