

ÇUKUROVA ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

Sporcular İçin İnvaziv Olmayan Sürekli Kan Basıncı Tahmini

Emine Nur TALİB

Biyomedikal Mühendisliği Anabilim Dalı

Mayıs, 2025

ÇUKUROVA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZ ONAYI

Sporcular İçin İnvaziv Olmayan Sürekli Kan Basıncı Tahmini

Emine Nur TALİB

Biyomedikal Mühendisliği Anabilim Dalı

Bu Yüksek Lisans Tezi 28/04/2025 Tarihinde Aşağıdaki Jüri Üyeleri Tarafından Değerlendirilmiş ve Oy Birliği / Oy Çokluğu ile Kabul Edilmiştir.

Jüri : Doç. Dr. Ahmet AYDIN (Danışman)
: Prof. Dr. M. Kerem ÜN
: Dr. Öğr Üyesi. Amira TANDİROVİÇ

Bu Tez Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Anabilim Dalında Hazırlanmıştır.
Tez No:

Prof. Dr. Sadık DİNÇER
Enstitü Müdürü

Bu çalışma, TÜBİTAK (Türkiye Bilimsel ve Teknolojik Araştırma Kurumu) tarafından desteklenmiştir. Proje No: 121E648

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge ve fotoğrafların kaynak gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

İÇİNDEKİLER

ÖZ	I
ABSTRACT.....	II
TEŞEKKÜR.....	III
ÇİZELGELER DİZİNİ	IV
ŞEKİLLER DİZİNİ.....	V
SİMGELER VE KISALTMALAR.....	VI
1. GİRİŞ	1
1.1. Egzersiz Testleri.....	1
1.1.1. Submaksimal Egzersiz Testleri	1
1.1.2. Maksimal Egzersiz Testleri.....	2
1.2. Kan Basıncı Ölçüm Yöntemleri	4
1.2.1. İnvaziv Ölçüm Yöntemi	4
1.2.2. İnvaziv Olmayan Ölçüm Yöntemi	5
1.3. Makine Öğrenmesi.....	10
1.3.1. Denetimli Makine Öğrenmesi	11
1.4. Makine Öğrenmesi Model Değerlendirilmesi.....	26
1.4.1. Yöntemler.....	26
1.4.2. Metrikler.....	26
1.5. Çalışmanın Amacı.....	29
2. ÖNCEKİ ÇALIŞMALAR.....	31
2.1. Makine Öğrenimi Tabanlı Kan Basıncı Tahmin Modelleri	31
2.2. Fiziksel Aktivite ve Cerrahi Süreçlerde KB Tahmini	31
2.3. Gerçek Dünya Uygulamaları ve Giyilebilir Cihazlar ile KB Tahmini.....	32
2.4. Genel Değerlendirme	33
3. MATERYAL VE METOT	35
3.1. Donanım.....	35
3.1.1. M5 Stack ECG Module 13.2.....	35
3.1.2. M5 Stack Heart Rate Unit	37
3.1.3. M5 Stack Core2	38
3.1.4. STAMP-S3.....	41
3.2. Verileri ESP-NOW Kablosuz İletişim Protokolü İle Merkez Donanıma Aktarması	43
3.3. Yazılım.....	44
3.4. Makine Öğrenmesi Kodu	44
3.4.1. Sinyalleri Filtreleme İşlemi.....	44
3.4.2. Özellik Çıkarma İşlemi	45

3.4.3. Normalizasyon	50
4. BULGULAR VE TARTIŞMA	53
4.1. Hazır veri seti kullanarak kan basıncı tahmini:.....	53
4.2. Geliştirilen Sistemle Dinlenirken Kan Basıncı Tahmini.....	57
4.3. Geliştirilen Sistemle Antrenman Yaparken Kan Basıncı Tahmini	59
5. SONUÇLAR VE ÖNERİLER	61
5.1. Sonuçlar	61
5.2. Öneriler	61
KAYNAKLAR	63
ÖZGEÇMİŞ	71



Sporcular İçin İnvaziv Olmayan Sürekli Kan Basıncı Tahmini

Emine Nur TALİB

Danışman: Doç. Dr. Ahmet AYDIN

Biyomedikal Mühendisliği Anabilim Dalı

ÖZ

Bu tezde farklı makine öğrenmesi modelleri kullanarak sporculara yönelik matşetsiz ve invaziv olmayan kan basıncı (KB) tahmini üzerine bir yöntem geliştirilmiştir. Geleneksel KB ölçüm yöntemleri İnvaziv ve invaziv olmayan olmak üzere ikiye ayrılmaktadır. Son yıllarda her iki yöntemin dezavantajlarını gidermek amacıyla vücut üzerinden kolay bir şekilde ölçülebilen elektrokardiyogram(ECG) ve fotoplatismogram(PPG) gibi biyosinyaller kullanarak dolaylı olarak KB ölçümü yapan sistemler büyük bir ilgi görmüştür. Bu çalışmada, ECG sinyalinde kalp atım hızı(HR),P-R süresi, R-R süresi, P genliği, R genliği ve T genliği özellikleri, PPG sinyalinde nabız aralığı(PPI), sistolik pik genliği(SPV), nabız dalga bitişi (PWE) ve Dikrotik çentiğin genliği (b) ile sistolik zirvenin genliği (a) arasındaki orandır. b/a oranı özellikleri ve her iki sinyali kullanarak hesaplanan nabız geçiş zamanı(PTT) özelliği hesaplanmıştır. Makine öğrenmesi modellerinin eğitimi ve test süreci için, hem hazır veri setleri hem de bu çalışma kapsamında geliştirilen özel donanım aracılığıyla toplanan özgün veriler kullanılmıştır. Tasarlanan sistem, gerçek zamanlı sinyal kaydı yapabilmekte olup, ölçümler koşu bandı üzerinde egzersiz yapan deneklerden alınmıştır. Bu yönüyle sistem, sporculara özel olarak değerlendirilmiş ve fiziksel aktivite sırasındaki KB değişimlerini yansıtabilecek nitelikte veri sağlamıştır. Elde edilen özellikler yardımıyla KB tahmini için farklı makine öğrenmesi modelleri denenmiştir. Test edilen makine öğrenmesi modelleri arasında diastolik KB için 2.3 ± 0.7 sistolik KB için 5 ± 1.3 MAE değeriyle en başarılı LASSO regresyon modeli görülmüştür. Çalışmada kullanılan ECG ve PPG sinyalleri, makine öğrenmesi modellerini eğitmek amacıyla belirli ön işleme adımlarına tabi tutulmuştur. Bu adımlar arasında sinyal filtreleme, özellik seçimi ve normalizasyon yer almaktadır. Test edilen makine öğrenmesi modellerinin performanslarını değerlendirmek üzere farklı veri setler kullanılmış ve modellerin doğruluğu değerlendirilmiştir. Bu çalışmada, literatürde dolaylı KB ölçümü için ECG ve PPG sinyallerini kullanan diğer çalışmalara kıyasla, daha az sayıda özellik kullanılarak yüksek doğruluğa sahip bir algoritma geliştirilmiştir. Sonuç olarak, geliştirilen sistem, non-invaziv ve sürekli kan basıncı tahmini için umut vadeden bir yaklaşım sunmaktadır.

Anahtar Kelimeler: Kan Basıncı, ECG, PPG, Makine Öğrenmesi

Non-invasive Continuous Blood Pressure Estimation For Athletes

Emine Nur TALİB

Advisor: Assoc. Prof. Ahmet AYDIN

Department of Biomedical Engineering

ABSTRACT

In this thesis, a method for cuffless and non-invasive blood pressure (BP) estimation targeted at athletes was developed using various machine learning models. Traditional BP measurement techniques are classified as invasive and non-invasive, both of which have certain limitations. In recent years, systems that estimate BP indirectly using biosignals such as electrocardiogram (ECG) and photoplethysmogram (PPG)—which can be easily measured from the body—have attracted significant attention as alternatives to overcome these disadvantages. In this study, several features were extracted: from the ECG signal—heart rate (HR), P-R interval, R-R interval, and the amplitudes of the P, R, and T waves; from the PPG signal—pulse period interval (PPI), systolic peak value (SPV), pulse wave end (PWE), and the ratio between the amplitude of the dicrotic notch (b) and the amplitude of the systolic peak (a).b/a ratio; and additionally, pulse transit time (PTT) was calculated using both signals. For the training and testing of the machine learning models, both publicly available datasets and original data collected via custom-designed hardware developed within the scope of this study were used. The designed system is capable of real-time signal acquisition, and the measurements were taken from subjects while running on a treadmill. Therefore, the system was specifically evaluated for athletic use, providing data that reflects BP variations during physical activity. Using the extracted features, several machine learning algorithms were tested for BP estimation. Among the tested models, the LASSO regression model achieved the best performance with a mean absolute error (MAE) of 2.3 ± 0.7 mmHg for diastolic BP and 5 ± 1.3 mmHg for systolic BP. The ECG and PPG signals used in the study were subjected to several preprocessing steps, including signal filtering, feature selection, and normalization, prior to training the models. In order to evaluate the generalization and accuracy of the models, different datasets were utilized during testing. Compared to other studies in the literature that estimate BP indirectly using ECG and PPG signals, this study developed a highly accurate algorithm using fewer features. In conclusion, the proposed system presents a promising approach for non-invasive and continuous blood pressure monitoring.

Keywords: Blood Pressure, ECG, PPG, Machine Learning

TEŞEKKÜR

Tez sürecinde her zaman desteğini esirgemeyen, bilgi ve tecrübeleriyle bana yol gösteren, anlayışı ve sabrıyla bana rehberlik eden danışmanım Sayın Doç. Dr. Ahmet AYDIN'a teşekkür ederim.

Tez çalışmamda görüş, öneri ve destekleriyle bana yol gösteren sayın Arş. Gör. Cemil KESKİNOĞLU'na teşekkür ederim.

Tez sunumunda ve savunmasında yer alan saygıdeğer jüri üyeleri Sayın Prof. Dr. M. Kerem ÜN ve Sayın Dr. Öğretim Üyesi Amira TANDİROVİÇ'e katkıları ve destekleri için ayrıca teşekkür ederim.

Bu çalışma, TÜBİTAK (Türkiye Bilimsel ve Teknolojik Araştırma Kurumu) tarafından desteklenen 121E648 numaralı ARDEB 1001 - Bilimsel ve Teknolojik Araştırma Projelerini Destekleme Programı kapsamında yürütülen "Salon Sporları İçin Atletik Performans Ölçüm Sistemi Geliştirilmesi" projesi çerçevesinde gerçekleştirilmiştir. Sağladıkları maddi destek ve katkılardan dolayı TÜBİTAK'a teşekkür ederim.

Varlığına minnettar olduğum anneme, hayatımı güzelleştiren ve anlamlandıran çocuğuma, bu süreçte bana sabır ve destekle eşlik eden sevgili eşime ve her zaman yanımda olan kıymetli aileme sonsuz teşekkür ederim.

ÇİZELGELER DİZİNİ

Çizelge 1.1. Egzersiz test tipleri ve özellikleri.....	3
Çizelge 1.2. Cıvalı tansiyon aletlerinde karşılaşılabilecek olası mekanik sorunlar	5
Çizelge 3.1. ECG modül teknik özellikleri	36
Çizelge 3.2. M5 Stack Heart Rate Unit teknik özellikleri.....	37
Çizelge 3.3. M5Stack Core2 teknik özellikleri	39
Çizelge 3.4. STAMP-S3 teknik özellikleri	41
Çizelge 3.5. ESP-NOW ile diğer kablusun iletişim protokolleri arasında karşılaştırma tablosu	44
Çizelge 4.1. Çalışmada kullanılan regresyon modellerinin hiperparametrelerinin tablosu.....	55
Çizelge 4.2. Çalışmada kullanılan makine öğrenmesi modelleri değerlendirme tablosu.....	56
Çizelge 4.3. Bu çalışmada elde edilen sonuçların, literatürde yer alan benzer çalışmalarla karşılaştırılma tablosu.....	56

ŞEKİLLER DİZİNİ

Şekil 1.1. KB İnvaziv ölçüm yöntemi	4
Şekil 1.2. Cıvalı tansiyon ölçüm cihazı.....	6
Şekil 1.3. Aeroid tansiyon ölçüm cihazı	7
Şekil 1.4. Otomatik koldan tansiyon ölçüm cihazı	8
Şekil 1.5. Bilekten tansiyon ölçüm cihazı	9
Şekil 1.6. Parmaktan tansiyon ölçüm cihazı	9
Şekil 1.7. 24 saat KB takibi için kullanılan KB ölçüm cihazı	10
Şekil 1.8. Makine öğrenmesi metotları	11
Şekil 1.9. Denetimli makine öğrenmesinin çalışma prensibi	11
Şekil 1.10. Regresyon problemlerinde denetimli makine öğrenmesinin çalışma prensibi.....	12
Şekil 1.11. Doğrusal regresyon	13
Şekil 1.12. Doğrusal regresyon ve Ridge regresyon	15
Şekil 1.13. Hava durumunu tahmin etmekte kullanılan basit bir karar ağacı	17
Şekil 1.14. Random forest ve karar ağacı	18
Şekil 1.15. Gradient boosting çalışma prensibi.....	19
Şekil 1.16. Komşu sayısı 5 olan bir KNeighbors Regresyon örneği	20
Şekil 1.17. MLP regrsyon örneği	21
Şekil 1.18. XGBoost çalışma presibi	22
Şekil 1.19. Bagging Regresor çalışma prensibi	24
Şekil 1.20. SVM regresyonunun çalışma prensibi	25
Şekil 3.1. Sistem diyagramı	35
Şekil 3.2. ECG modül şeması	36
Şekil 3.3. M5 Stack Heart Rate Unit şeması	38
Şekil 3.4. Sporcu üstündeki donanım.....	40
Şekil 3.5. Donanımın sporcu üstündeki hali	40
Şekil 3.6. STAMP-S3 şeması.....	42
Şekil 3.7. Bilgisayara bağlı STAMP-S3	42
Şekil 3.8. Çalışmada kullanılan PTT değerleri	50
Şekil 4.1. Hazır veri setinden alınan ECG sinyal filtreleme	54
Şekil 4.2. Hazır veri setinden alınan PPG sinyal filtreleme	54
Şekil 4.3. Sensörlerle ölçülen ECG sinyal filtreleme	58
Şekil 4.4. Sensörlerle ölçülen PPG sinyal filtreleme	58
Şekil 4.5. Antrenman sırasında yapılan testte sistem görüntüsü	59

SİMGELER VE KISALTMALAR

BMI	: vücut kitle indeksi
ECG	: elektrokardiyogram
EKK	: en küçük kareler yöntemi
KAH	: kalp atım hızı
KAHex	: egzersiz sırasında kalp atım hızı
KB	: Kan Basıncı
PPG	: fotoplatismogram
PTT	: n nabız geçiş zamanı
SPWT	: Self-Paced Walking Test
Submaksimal	: maksimal altı
VO ₂ Max	: maksimum oksijen alımı

1. GİRİŞ

Sporcunun performansını doğru bir şekilde geliştirebilmesi için uygun bir antrenman programı planlanması gerekmektedir. Bu programların hazırlanmasında, sporcunun fiziksel özellikleri ve egzersiz testlerinden elde edilen parametreler büyük bir önem taşımaktadır. Performans değerlendirme ve geliştirme amacıyla gerçekleştirilen bu testler, antrenman süreçlerinin etkinliğini artırmak, sakatlık risklerini azaltmak ve genel sağlık durumunu izlemek açısından kritik bir rol oynamaktadır. Örneğin, spor bilimleri alanında kullanılan güç ve kuvvet testleri, sporcuların fiziksel kapasitelerini değerlendirmek ve performanslarını artırmak için önemli araçlardır(Aktaş ve Baydemir, 2024).

1.1. Egzersiz Testleri

Egzersiz testleri, bireyin fiziksel kapasitesini, kardiyovasküler sağlığını ve dayanıklılığını değerlendirmek için kullanılan testlerdir(Ashley ve ark, 2000). Bu testler, hastaların tıbbi durumlarını değerlendirmek için kullanılmasının yanı sıra sporcuların performansını ölçmek ve geliştirmek için de kullanılabilmektedir (Nelson ve Asplund, 2016).

Egzersiz testleri, hastaların durumunu değerlendirmek için kardiyovasküler ve pulmoner hastalıkların teşhisinde, hastalığın ilerleyişinin izlenmesinde, cerrahi müdahaleler öncesinde risk değerlendirmesi yapılmasında ve uygulanan tedaviye verilen yanıtın değerlendirilmesinde kullanılabilmektedir (Palange ve ark, 2006). Sporcular için ise bu testler, antrenman programlarını optimize etmek, dayanıklılık seviyelerini değerlendirmek ve sporcuların fiziksel sınırlarını belirlenmek amacıyla uygulanabilmektedir(Volis ve Zafir, 2024). Egzersiz testleri, yoğunluk açısından submaksimal ve maksimal olarak sınıflandırılmaktadır.

1.1.1. Submaksimal Egzersiz Testleri

Bireyin maksimum kapasitesine ulaşmadan, belirli bir hedef değere örneğin kalp atış hızına ya da egzersiz yoğunluğuna kadar yapılan testlerdir(Reed ve ark., 2020). Bu testler, maksimum çaba gerektirmediği için yaşlılar ve kronik rahatsızlıkları olan bireylerde sıklıkla tercih edilmektedir(Noonan ve Dean, 2000). Submaksimal testler yardımıyla, doğrudan ölçüm yapmadan bazı fizyolojik değerler dolaylı yoldan tahmin edilmektedir. VO_2Max tahmini için yapılan testler, Submaksimal testlere örnek olarak verilebilir. VO_2Max , sporcuların aerobik güçleri hakkında önemli bilgiler sağlar. Ayrıca, kardiyovasküler sistemle ilgili hastalıklara (örneğin, kalp yetmezliği) sahip bireyler için de değerli bilgiler sunabilir(Sartor ve ark, 2013). Submaksimal testler tahmine dayalı ve performansa dayalı olmak üzere iki ana kategoriye ayrılmaktadır(Noonan ve Dean, 2000).

Tahmine dayalı Submaksimal testler

Bu testler belirli yükler altındaki HR ve maksimum oksijen tüketimi VO₂ gibi parametreleri ölçerek kişinin maksimal aerobik kapasitesini tahmin etmek için kullanılır(Sartor ve ark, 2013). Tahmine dayalı testler yardımıyla kardiyovasküler sistemin fonksiyonel kapasitesini ölçmek için kullanılan VO₂ max parametresini tahmin etmek için kullanılır.

Performansa dayalı Submaksimal testler

Bu testler bireylerin günlük yaşamda sıkça karşılaştıkları standart fiziksel aktivitelere verdikleri tepkileri değerlendirmek amacıyla uygulanır. SPWT(Self-Paced Walking Test) performansa dayalı submaksimal testlere örnek olarak verilebilir(Noonan ve Dean, 2000). SPWT testi, yaşlı ve gücü zayıf olan bireyler için geliştirilen bir egzersiz testidir. Bu test, 250 metre uzunluğundaki kapalı bir koridorda üç farklı hızda serbest yürüyüşü içermektedir(Noonan ve Dean, 2000). Test sırasında yürüme hızı, süre, adım frekansı, adım uzunluğu, kalp atış hızı(KAH) ve tahmini maksimum oksijen alımı (VO₂max) gibi çeşitli egzersiz yanıtları değerlendirilmektedir (Noonan ve Dean, 2000).

Sporcular için Submaksimal egzersiz testleri, sporcuların fizyolojik durumlarını değerlendirmek için zaman açısından verimli, düşük fizyolojik yük oluşturan ve saha ya da laboratuvar ortamlarında kolayca uygulanabilen yöntemlerdir(Shushan ve ark, 2023).

HR, Submaksimal egzersiz testlerinde bakılan önemli parametrelerden bir tanesidir. Egzersiz sırasında ölçüldüğü için KAHex olarak bilinmektedir. Aerobik kapasitenin bir göstergesi olarak kullanılan bu parametre oksijen tüketimi ile ilişkilendirilmektedir.(Shushan ve ark, 2023).

1.1.2. Maksimal Egzersiz Testleri

Maksimal testler, bireyin maksimum fiziksel kapasitesine ulaşmasını hedefler. Bu testlerde, birey tükenene kadar veya fizyolojik sınırlarına ulaşana kadar egzersize devam eder. Sporcuların aerobik kapasitelerini değerlendirmek için yaygın olarak kullanılan bu testler, yüksek yoğunluklu antrenman programlarının tasarlanmasında da önemli bir rol oynamaktadır(Barker ve Armstrong, 2010).

Bazı egzersiz testlerin özellikleri Çizelge 1.1’de gösterilmektedir.

Çizelge 1.1. Egzersiz test tipleri ve özellikleri

Yöntem	Teknik donanım	Yoğunluk	Değerlendirme	Standardizasyon	Tekrar edilebilirlik	Maliyet
Merdiven Çıkma	0	Mak/mak	Postop risk, FK	0	0	0
6DYT	+	Submak/mak	FK	++	++	+
Shuttle test	++	Maksimal	FK	+++	++	+
Egzersiz provokasyon	+++	Submaksimal	Bronş hiperrektivitesi	++	++	++
Kardiyak stres test	+++	Submaksimal	İskemi, aritmi	+++	+++	+++
KPET	++++	Maksimal	FK, multi sistem değerlendirme	++	+++	++++

6DYT: 6 dakika yürüme testi, KPET: Kardiyopulmoner egzersiz testleri, FK: Fonksiyonel kapasite

Egzersiz testlerinde uygulanan teste ve bireyin durumuna göre belirli biyolojik parametrelere doğru ya da dolaylı yoldan bakılmaktadır. Bu testlerde bakılan önemli parametrelerden bir tanesi kan basıncıdır (KB). KB bireyin kardiyovasküler sisteminin stres altındaki tepkisini değerlendirmek için önemli bir parametre olmasının yanı sıra sporcunun performans değerlendirilmesinde büyük bir öneme sahiptir.

KB değerlerinde ani yükselmeler kalp krizi gibi kardiyovasküler riskleri arttırabilir(Keller ve ark, 2022). Ayrıca sporcular arasında en yaygın hastalıklardan bir tanesi kardiyovasküler hastalığı olan hipertansiyondur. Bu nedenle sporcunun düzenli KB takibi, hem anlık sağlık durumunun değerlendirilmesi hem de zamanla değişen performans seviyelerinin belirlenmesi açısından da büyük bir öneme sahiptir.

Kan basıncı ölçümleri, test öncesi, sırasında ve sonrasında yapılabilir. Egzersiz sırasında sistemik dolaşımda belirli değişiklikler meydana gelir ve bu değişiklikler kan basıncının değişmesine sebep olur(Andersen, 1971).

Dinlenmeden egzersize geçiş sırasında, çalışan kasların damarlarında ani ve güçlü bir genişleme meydana gelir. Bu genişlemeye rağmen, sistemik arteriyel basınç artış gösterir. Egzersiz sırasında arteriyel basınç, aktivite yoğunluğuna bağlı olarak yükselir, ardından sabit bir seviyeye ulaşarak bu seviyede korunur. Egzersizin sona ermesiyle birlikte kan basıncı aniden düşer ve dinlenme öncesi seviyelerin altına inebilir. Bu minimum basınç seviyesi, egzersizin bitişinden sonraki 5-10 saniye içinde gerçekleşir. Daha sonra basınç hafifçe yükselerek egzersiz öncesi seviyelerin üzerine çıkar.

Sistolik kan basıncı, egzersiz sırasında artan iş yoğunluğuna paralel olarak yükselir ve maksimum egzersiz sırasında 200 mmHg'nin üzerine çıkabilir. Diastolik kan basıncı ise hafif ve orta yoğunluklu egzersizlerde genellikle sabit kalırken, ağır egzersizlerde hafif bir artış gösterebilir. Kan basıncı değişiklikleri, ortam sıcaklığı, egzersiz süresi, şiddeti ve egzersizin aniden mi yoksa kademeli olarak mı sonlandırıldığı gibi faktörlerden etkilenir. Bu fizyolojik tepkiler, bireyin kardiyovasküler kapasitesini değerlendirmede ve egzersiz protokollerini optimize etmede kritik bir rol oynar(Andersen, 1971). Kısacası egzersiz sırasında kan basıncı, vücudun fiziksel aktiviteye uyum sağlaması için değişmektedir. Sistolik basınç yoğunluğa göre önemli ölçüde artarken, diastolik

basınç genellikle sabit kalır. Egzersiz sonrası toparlanma süreci, bireysel ve çevresel faktörlere bağlı olarak değişiklik gösterebilir.


Kan basıncının doğru bir şekilde ölçülmesi, sporcuların performans takibi, hastaların tedavi süreçleri ve sağlıklı bireylerin genel sağlık durumlarının değerlendirilmesi açısından büyük önem taşır. Doğru teşhis ve etkili bir değerlendirme yapabilmek için ölçümlerin hassas, güvenilir ve standart yöntemlerle gerçekleştirilmesi gerekmektedir. Bu konuda Türkiye Kardiyoloji Derneği'nin "Kan Basıncının Ölçümü ve Klinik Değerlendirme" kılavuzu detaylı bilgiler sunmaktadır (Türk Kardiyoloji Derneği, 2023).

1.2. Kan Basıncı Ölçüm Yöntemleri

KB ölçümü için kullanılan klasik yöntemler invaziv ve invaziv ölçüm yöntemi olarak ikiye ayrılmaktadır.

1.2.1. İnvaziv Ölçüm Yöntemi

Bu yöntemde ölçüm atardamara yerleştirilen kateter aracılığıyla gerçekleştirilir, kateter hassas bir basınç ölçüm cihazına bağlanır. Bu yöntem sayesinde basınçtaki küçük değişiklikleri yüksek doğrulukla tespit edilmektedir(Alexander ve ark, 2013). Genellikle yoğun bakım ve cerrahi alanlarında uygulanır. Ancak invaziv olduğu için enfeksiyon ve damar hasarı riski taşır ayrıca egzersiz testleri sırasında kullanılması oldukça zordur(Ward ve Langton, 2007). İnvaziv ölçüm yöntemi Şekil1.1’de gösterilmektedir



Şekil 1.1. KB İnvaziv ölçüm yöntemi

1.2.2. İnvaziv Olmayan Ölçüm Yöntemi

Bu yöntem tıkalı kaf kullanılarak gerçekleştirilmekte ve genellikle klinik ve ev kullanımı için tercih edilmektedir(Meidert ve Saugel, 2018). İnvaziv olmayan ölçüm için kullanılan cihazlar cıvalı, aneroid ve elektronik olarak üç türe ayrılmaktadır (AKSOY ve ark, 2003).

Cıvalı tansiyon ölçüm cihazı

Cıvalı kan basıncı ölçüm cihazları, kan basıncı ölçümünde altın standart olarak kabul edilmekte olup, yüksek doğruluk ve güvenilirlikleriyle bilinmektedir(Williams ve ark, 2004). Ancak, cıvanın çevreye toksik etkileri bu yöntemin birçok ülkede kullanımı yasaklanmıştır.(Williams ve ark., 2004). Bu cihazlar, mekanik bir sorun olmadığı sürece düzenli kalibrasyon gerektirmez ve uzun süre güvenilir ölçümler sunar. Cıvalı tansiyon aletlerinde karşılaşılabilecek olası mekanik sorunlar Çizelge 1.2'de özetlenmiştir.

Çizelge 1.2. Cıvalı tansiyon aletlerinde karşılaşılabilecek olası mekanik sorunlar

Kontrol Edilmesi Gerekenler	Durumu
Cıva seviyesi sıfır noktasında mı?	Evet/Hayır
Cam sütun sağlam mı?	Evet/Hayır
Rakamlar okunuyor mu?	Evet/Hayır
Manşet sağlam mı?	Evet/Hayır
Hortum sağlam mı?	Evet/Hayır
Anahtar çalışıyor mu?	Evet/Hayır


Çizelge 1.2'deki soruların bir ya da daha fazlasının cevabı evet ise, bu durum aletin mekanik bir sorun yaşadığını gösterir ve kalibrasyon yapılması gerektiği anlamına gelir(Ghareeb ve ark., 2021).

Cıvalı tansiyon aletin çalışma prensibi

Cıvalı tansiyon ölçüm cihazının kullanımı, manşetin kola yerleştirilmesiyle başlar. Şişirilebilir manşet, brakial arterin üzerine hizalanarak doğru şekilde konumlandırılır. Ardından, kauçuk pompa yardımıyla manşet şişirilir ve brakial arter sıkıştırılarak kan akışı geçici olarak durdurulur. Şişirme işlemi devam ettikçe, manşet içindeki hava basıncı cıva sütununa iletilir ve cıva seviyesi uygulanan basınca bağlı olarak yükselir(Valler-Jones ve Wedgbury, 2005). Ölçüm aşamasında, manşetin basıncı yavaşça düşürülerek kanın tekrar akmasına izin verilir ve stetoskop aracılığıyla Korotkoff sesleri dinlenir(Valler-Jones ve Wedgbury, 2005). Korotkoff sesleri, kan akışının başlamasıyla stetoskop aracılığıyla duyulabilen seslerdir. İlk duyulan Korotkoff sesi, sistolik basıncı, seslerin tamamen kaybolduğu nokta ise diastolik basıncı gösterir. Son olarak, cıva sütunu

kan basıncına bağılı olarak yavaşça alçalır ve ölçülen değerler mmHg cinsinden skaladan okunarak tansiyon değeri belirlenir.


Ölçüm sırasında, Korotkoff seslerine dayalı oskültatuvar yöntem kullanılır. Bu yöntem, kan basıncının stetoskop ile dinlenerek manuel olarak ölçülmesini sağlar(Bonnafox, 1996). Oskültatuvar yöntem, doğru ve güvenilir ölçüm yapabilmek için eğitilmiş kullanıcı gerektirir. Cıvalı tansiyon ölçüm cihazlarının bazı dezavantajları arasında büyük ve ağır olmaları ile kullanıcı eğitimi gerektirmeleri yer almaktadır. Cıvalı tansiyon ölçüm cihazı aşağıdaki Şekil 1.2’de gösterilmiştir.



Şekil 1.2. Cıvalı tansiyon ölçüm cihazı

Aneroid tansiyon ölçüm cihazı

Kan basıncı ölçümünde cıvalı aletler gibi Korotkoff seslerine dayalı oskültatuvar yöntem kullanılır. Cıva yerine mekanik sistemler kullanarak kan basıncını ölçmektedir(McVicker, 2001). Aneroid tansiyon ölçüm cihazının parçaları Şekil 1.3’de gösterilmiştir.



Şekil 1.3. Aneroid tansiyon ölçüm cihazı

Ölçüm sırasında cıvalı ve aneroid tansiyon ölçüm cihazları arasındaki temel farklar, çalışma prensipleri ve doğruluk açısından ortaya çıkar. Cıvalı tansiyon aletleri, basınç değişimlerine tepki olarak cıva sütununun hareketiyle ölçüm yaparken, aneroid cihazlar metal diyafram ve yay mekanizması kullanarak basıncı belirler. Cıvalı cihazlar altın standart olarak kabul edilir(McVicker, 2001) ve mekanik bir sorun olmadığı sürece kalibrasyon gerektirmezken, aneroid cihazlar zamanla hassasiyet kaybına uğrayabilir ve düzenli olarak kalibre edilmelidir(Farhan ve ark, 2020). Ölçüm sırasında, cıvalı cihazların dik durması gerekir ve cıva seviyesi yavaşça yükselip alçalırken, aneroid cihazlarda ibrenin hareketi hızlıdır ve sarsıntılardan etkilenebilir. Cıvalı aletler daha güvenilir ölçüm sağlarken, cıva toksisitesi nedeniyle birçok ülkede yasaklanmıştır(Buchanan ve ark, 2011). Buna karşın, aneroid cihazlar çevreye zararlı madde içermediği için daha güvenlidir ve hafif yapıları sayesinde daha taşınabilir ve kullanımı daha pratiktir. Eğer yüksek doğruluk gerektiren ölçümler isteniyorsa, cıvalı tansiyon aletleri tercih edilirken, günlük kullanımda pratikliği nedeniyle aneroid cihazlar daha yaygın kullanılmaktadır.

Otomatik tansiyon ölçüm cihazı

Otomatik kan basıncı ölçüm cihazları, genellikle osilometrik yöntemi kullanan modern tansiyon aletleridir(Sharman ve ark, 2023). Bu cihazlar, kola veya bileğe takılan şişirilebilir bir manşet, basınç sensörleri ve dijital bir ekran içerir. Kullanımı kolay olduğu için hastanelerde, kliniklerde ve evde yaygın olarak tercih edilir. Cıvalı ve aneroid ölçüm cihazlarının aksine otomatik ölçüm yaparak insan hatasını en aza indirir ve kullanımı için herhangi bir özel eğitim gerektirmez. Kullanıcı, yalnızca manşeti doğru konumlandırarak cihazı çalıştırır ve birkaç saniye içinde sistolik, diastolik basınç ve nabız değerlerini dijital ekrandan okuyabilir(Li ve ark, 2020). Bu nedenle,

elektronik cihazlar özellikle evde bireysel kullanım ve hasta takibi için pratik bir seçenek sunar. Ancak, hareket, yanlış manşet yerleşimi veya pil seviyesi gibi dış etkenler ölçüm doğruluğunu etkileyebilir. Otomatik aletlerin kalibrasyonun kontrol edilmesi aneroidlerin aksine genellikle nadiren gerekir.

Kullanım yerine ve amacına göre tansiyon ölçüm cihazları üç farklı gruba ayrılır:

Kullanım yerine göre:

1. Üst kol tipi
2. Bilek tipi
3. Parmak ucu tipi

Kullanım amacına göre:

1. Evde ölçüm için
2. Klinik kullanım için
3. 24 saat kan basıncı takibi için (Ambulatuvar ölçüm)

Üst kol tipi cihazlar, kola takılan manşet ile ölçüm yapar ve genellikle en doğru sonuçları verir(Karaçay, 2022). Bilek tipi cihazlar, bileğe takılarak kullanılır ve taşınabilirliği sayesinde evde veya seyahatlerde tercih edilir; ancak doğru sonuçlar almak için kolun kalp hizasında tutulması gerekir. Parmak ucu tipi cihazlar, parmağa takılarak hızlı ölçüm sağlar, ancak hassasiyeti düşük olduğu için genellikle profesyonel kullanım yerine kişisel takip amaçlı ya da hızlı bir tahmini ölçüm



Şekil 1.4. Otomatik koldan tansiyon ölçüm cihazı (Respirox, 2025a)

için kullanılır. Üst kol, bilek ve parmak tipi tansiyon ölçüm cihazları Şekil 1.5 ve Şekil1.6 ‘da gösterilmektedir.



Şekil 1.5. Bilekten tansiyon ölçüm cihazı (Respirox, 2025b)



Şekil 1.6. Parmaktan tansiyon ölçüm cihazı (Edwards Lifesciences, 2025).

Ev ölçümleri için kullanılan modeller kullanımı kolay ve hafızalı modellerdir önceki ölçümleri kaydedebilir. Klinik kullanım için geliştirilen otomatik cihazlar, daha hassas sensörlere sahiptir ve profesyonel ortamda hızlı ölçüm yaparak zaman kazandırır. 24 saat kan basıncı takibi için kullanılan otomatik cihazlar, hastanın günlük aktiviteleri sırasında belirli aralıklarla ölçüm yapar ve verileri kaydederek doktorların analizine sunar. Bu yöntem, hipertansiyon tanısı koymak veya tedavi sürecini takip etmek için kullanılır. 24 saat takibi için kullanılan tansiyon cihazı Şekil 1.7’de gösterilmektedir.




Şekil 1.7. 24 saat KB takibi için kullanılan KB ölçüm cihazı (Medwelt, 2025).

Piyasada bulunan bu üç çeşit tansiyon ölçüm cihazının her birinin ayrı ayrı dezavantajları bulunmakta ve bundan dolayı bu cihazların geliştirilmesi gereken yönleri mevcuttur. Sağlık personellerinin ideal olarak görmek istediği tansiyon ölçüm cihazları, invaziv olmayan, gerçek zamanlı ölçüm yapabilen, hastayı rahatsız etmeden uzun süre kullanılabilen, yüksek doğruluk sağlayan ve hastanın herhangi bir eğitim almadan kolayca kullanabileceği cihazlar olmalıdır.

Bu gereksinimi karşılayabilmek için modern teknolojinin en güçlü araçlarından bir tanesi M-makine öğrenmesine başvurulabilir. Özellikle son yıllarda, makine öğrenmesi teknikleri kullanılarak kan basıncının dolaylı yöntemlerle tahmin edilmesi üzerine çalışmalar artmıştır.

1.3. Makine Öğrenmesi


Yapay zekâ, insan zekâsını taklit eden ve algılama, akıl yürütme, öğrenme, çevreyle etkileşim, problem çözme, karar verme ve yaratıcılık gibi bilişsel yetileri makineler aracılığıyla gerçekleştiren bir teknolojidir (Rai ve ark, 2019). Yapay zekânın bir alt dalı olan makine öğrenmesi, bilgisayarların mevcut verilerden öğrenerek bu bilgiyi kullanıp tahmin yapma ve karar alma yeteneğini geliştirmesini sağlar (Hurwitz ve Kirsch, 2018). Makine öğrenmesinin Şekil 1.8 ile gösterildiği gibi 4 metodu vardır.



Şekil 1.8. Makine öğrenmesi metotları

1.3.1. Denetimli Makine Öğrenmesi

Bir modelin, giriş verileri (X) ve bu verilere karşılık gelen doğru çıkış verileri (Y) kullanılarak eğitildiği bir makine öğrenmesi yöntemidir. Bu süreçte model, girdiler ile çıktılar arasındaki ilişkiyi öğrenir ve bu bilgiyi kullanarak yeni ve bilinmeyen veriler için tahmin yapabilir (Liu ve Wu, 2012). Denetimli makine öğrenmesinin çalışma prensibi Şekil 1.9’da gösterilmektedir.



Şekil 1.9. Denetimli makine öğrenmesinin çalışma prensibi

Denetimli öğrenme modelleri sınıflandırma ve regresyon olarak iki çeşide ayrılmaktadır (Mahesh, 2020).


Sınıflandırma modelleri

Girdilerden yola çıkarak verileri iki veya daha fazla sınıfa ayırmayı amaçlar (Bilgin ve Şentürk, 2019). Örneğin, bir sınıftaki öğrencilerin belirli bir derste başarılı olup olmadığını tahmin etmek bir sınıflandırma problemidir. Bu tahmin için girdi olarak öğrencilerin önceki yıllardaki aynı

dersteki notları veya diğer derslerdeki performansları kullanılabilir. Regresyon için kullanılan tüm algoritmaları sınıflandırma için kullanılabilir.

Regresyon modelleri

Girdiler ile çıktı arasındaki ilişkiyi modellemek ve sürekli bir sayısal değer tahmin etmek için kullanılır(Kilic, 2013). Örneğin, bir sınıftaki öğrencilerin belirli bir derste alacakları notları tahmin etmek bir regresyon problemidir. Bu tahmin için yine öğrencilerin geçmiş yıllardaki aynı dersteki notları veya diğer derslerdeki notları girdi olarak kullanılabilir. Regresyon problemlerinde denetimli makine öğrenmesinin çalışma prensibi Şekil 1.10'da gösterilmektedir.



Şekil 1.10. Regresyon problemlerinde denetimli makine öğrenmesinin çalışma prensibi

Gerçekleştirilen bu tez çalışmasında, sürekli bir değer için KB tahmin yapıldığından denetimli öğrenme yöntemlerinden regresyon modelleri kullanılmıştır.


Doğrusal Regresyon

Bağımlı bir değişken y ile bir veya daha fazla bağımsız değişken $(x_1, x_2, \dots, x_p)$ arasındaki doğrusal ilişkiyi modellemek için kullanılan istatistiksel bir yöntemdir(Kilic, 2013). Bu model, bağımlı değişkeni bağımsız değişkenlerin ağırlıklı toplamı ve bir hata terimi (ϵ) ile ifade eder(Şahinler, 2000) ve genel formülü şu şekildedir:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p + \epsilon \quad (1.1)$$

Bu modelde, $\beta_0, \beta_1, \dots, \beta_p$ katsayıları model parametreleri olarak adlandırılır ve ϵ hata terimi, modelin açıklayamadığı rastgele değişkenlikleri temsil eder. Makine öğrenmesi bağlamında,

doğrusal regresyonun amacı, eğitim verilerini kullanarak bu parametreleri öğrenmek ve en iyi tahmini sağlayan doğrusal modeli oluşturmaktır. Modelin parametrelerini belirlemek için en yaygın kullanılan yöntem, En Küçük Kareler Yöntemidir. Bu yöntem, gerçek değerler (y) ile modelin tahmin ettiği değerler $\hat{y}$ arasındaki farkların karelerini hesaplayarak toplamını en küçük yapacak doğrusal fonksiyonu bulmaya çalışır(Şahinler, 2000). Şekil 1.11’de, basit doğrusal regresyonun nasıl çalıştığını görselleştirilmiştir. Şekildeki siyah çarpılar, gerçek veri noktalarını temsil ederken, kırmızı çizgi en iyi tahmin yapan regresyon doğrusunu göstermektedir.



Şekil 1.11. Doğrusal regresyon

Modelin amacı, bu çizgiyi en iyi şekilde belirleyerek tahminleri optimize etmektir. Modelin başarısı, tahmin edilen değerlerin gerçek değerlere ne kadar yakın olduğuna bağlıdır. Bu nedenle, hataların kareleri alınarak toplanır ve bu toplam en küçük olacak şekilde modelin katsayıları hesaplanır(Vupa ve Alma, 2008).

Doğrusal regresyonun iki temel amacı var: bunlardan birincisi irincisi, modeldeki parametrelerin yorumlanması yoluyla bağımsız değişkenler ile bağımlı değişken arasındaki ilişkiyi anlamayı sağlar. İkincisi, daha önce gözlemlenmemiş girişler için gelecekteki çıktıları tahmin etmeye yardımcı olur. Bu yönleriyle, doğrusal regresyon açıklayıcı analiz ve tahminleme süreçlerinde yaygın olarak kullanılan temel bir yöntemdir. Doğrusal regresyon, basit doğrusal regresyon ve çoklu doğrusal regresyon olmak üzere ikiye ayrılır:

Basit doğrusal regresyon, tek bir bağımsız değişken ile bağımlı değişken arasındaki ilişkiyi modellemek için kullanılır(Tranmer ve Elliot, 2008).Çoklu doğrusal regresyon, birden fazla

bağımsız değişkeni kullanarak daha karmaşık ilişkileri modellemeye olanak tanır ve böylece daha kapsamlı tahminler yapılabilir (Tranmer ve Elliot, 2008).

Bu yöntem, özellikle istatistik, veri bilimi ve makine öğrenmesi alanlarında veri analizi ve tahminleme için temel bir araç olarak kabul edilir.

- **Ridge regresyon:**


Ridge regresyon (L2 regularization), çok değişkenli regresyon modellerinde hata kareler toplamını minimize eden katsayıları belirlemek için kullanılan bir yöntemdir (McDonald, 2009). Bu yöntemde, modelin katsayılarına bir ceza (L2 cezası) eklenerek aşırı öğrenme önlenir ve modelin daha iyi genelleme yapması sağlanır. Aşırı öğrenme, modelin eğitim verisine aşırı uyum sağlaması ancak yeni verilerde doğru tahmin yapamaması durumudur. Ridge regresyon, bu soruna karşı dirençlidir ve yüksek boyutlu veri setlerinde daha istikrarlı sonuçlar üretir (Alpu, Şamkar, ve Altan, 2010). Bu yöntemin önemli bir özelliği, tüm değişkenleri modele dahil etmesi ancak ilgisiz değişkenleri tamamen çıkarmak yerine katsayılarını sıfıra yaklaştırarak etkilerini azaltmasıdır. Böylece, önemli değişkenler korunurken gereksiz olanlar model üzerinde fazla ağırlık oluşturmaz (Büyüküysal, 2010). Ridge regresyonunun başarısı, ceza katsayısı λ (lambda) değerinin doğru seçilmesine bağlıdır. Lambda değeri çok büyük olursa model fazla sadeleşir ve bazı önemli değişkenlerin etkisi azalırken, çok küçük olursa ceza etkisi düşük olur ve model gereksiz değişkenlere fazla önem vererek aşırı öğrenme riski oluşturabilir. Ridge regresyonun matematiksel Eşitlik 1.2’de gösterilmektedir.

$$J(\beta) = \sum_{i=0}^n (y_i - \hat{y}_i)^2 + \lambda \sum_{j=1}^p \beta_j^2 \quad (1.2)$$

$J(\beta)$, modelin optimize etmeye çalıştığı hata fonksiyonu, y_i gerçek değerleri, $\hat{y}_i$ ise modelin tahmin ettiği değerleri, λ (lambda), düzenlileştirme parametresini ve modelin katsayılarını küçültme derecesini göstermektedir.

$\sum_{j=1}^p \beta_j^2$, regresyon katsayılarının karelerinin toplamını ifade eden L2 ceza terimidir.

Ridge regresyon, özellikle çok sayıda bağımsız değişken içeren yüksek boyutlu veri setlerinde güçlü ve dengeli tahminler yapabilen bir yöntemdir. Doğrusal regresyon ve Ridge regresyon arasındaki farkı açıklayan grafik Şekil 1.12’de gösterilmektedir.



Şekil 1.12. Doğrusal regresyon ve Ridge regresyon

Grafikte, kırmızı çizgi standart doğrusal regresyon modelini, mavi kesikli çizgi ise Ridge regresyon modelini temsil etmektedir. Ridge regresyon, katsayıları küçülterek modelin daha düzgün hale gelmesini sağlar ve aşırı öğrenmeyi önler. Küçük λ değerlerinde modelin standart regresyona daha yakın olduğu, büyük λ değerlerinde ise katsayıların sifıra yaklaştığı gösterilebilir.

- **Lasso regresyon**

Değişken seçimi ve regularizasyonu aynı anda gerçekleştiren bir regresyon yöntemidir. En küçük kareler(EKK) yönteminin alternatifi olarak, çoklu doğrusal bağlantı ve aşırı öğrenme sorunlarına karşı etkili bir çözüm sunar(Ranstan ve Cook, 2018). Çoklu doğrusal bağlantı bir regresyon modelinde bağımsız değişkenler (özellikler) arasında yüksek derecede doğrusal bir ilişki olduğunda ortaya çıkar. Başka bir deyişle, bağımsız değişkenlerin birbiriyle yüksek korelasyona sahip olması durumudur. Lasso, modeldeki katsayıları sifıra doğru zorlamak için L1 tipi ceza terimi kullanır. (Ranstan ve Cook, 2018)Bu ceza parametresi λ , katsayıların büzülme miktarını belirler ve λ sifır olduğunda EKK ile aynı sonucu verirken, yeterince büyük olduğunda bazı katsayıları sifıra eşitler. LASSO regresyonunun matematiksel denklem 1.3’de gösterilmektedir.

$$J(\beta) = \sum_{i=0}^n (y_i - \hat{y}_i)^2 + \lambda \sum_{j=1}^p |\beta_j| \quad (1.3)$$

Böylece Lasso, değişken seçimi yapar ve daha yorumlanabilir, sade modeller oluşturur. Lasso'nun avantajı, modelin daha düşük varyansla çalışırken yanlışlık eklemesi ve gereksiz değişkenleri sıfıra eşitlemesidir. Ridge Regresyon ile benzerlik gösterse de, Ridge herhangi bir parametreyi sıfırlamazken, Lasso bunu yaparak daha basit modeller üretir. Lasso, genellikle büyük veri setlerinde ve biyostatistik gibi alanlarda tercih edilir.

Doğruluğu en yüksek olan lasso regresyon modeli(Kubat, 1999) seçilmiştir.

- **Elastic Net Regresyonu:**


Bu yöntem, Lasso regresyonu (L1 ceza terimi) ve Ridge regresyonu (L2 ceza terimi) tekniklerini birleştirir(Aytekin, 2021). Elastic Net, bu iki ceza teriminin bir kombinasyonunu kullanarak, verinin doğrusal bir modelle en iyi şekilde uyum sağlamasını amaçlar. Elastic Net regresyonunun matematiksel denklemi Denklem 1.4'te gösterilmektedir.

$$J(\beta) = \sum_{i=0}^n (y_i - \hat{y}_i)^2 + \lambda \sum_{j=1}^p \beta_j^2 \quad (1.4)$$

Lasso regresyonu, değişken seçimi konusunda güçlüdür ve önemli olmayan değişkenlerin katsayılarını sıfıra indirir. Ancak, verilerde yüksek korelasyon varsa Lasso, tüm korelasyonlu değişkenleri sıfıra indirebilir. Ridge regresyonu, bu sorunu biraz daha hafifletir çünkü cezayı tüm katsayılaraya yayar, ancak değişken seçiminde zayıf kalabilir. Elastic Net, her iki yöntemden de yararlanarak hem değişken seçimi yapabilir hem de yüksek korelasyona sahip değişkenleri etkili bir şekilde modele dahil edebilir(Aytekin, 2021). Bu sayede, model daha istikrarlı ve doğru sonuçlar elde edebilir. Elastic Net'in uygulanması genellikle iki ana parametreyle yapılır: alpha (Lasso ve Ridge ceza terimlerinin birleşimi) ve lambda (ceza teriminin büyüklüğü). Bu parametrelerin doğru şekilde ayarlanması, modelin başarısını büyük ölçüde etkiler(Zou ve Hastie, 2005)

- **Karar ağacı**

Hem sınıflandırma hem de regresyon problemlerinde kullanılan, veri kümesini belirli kurallara göre bölerek tahmin yapmaya çalışan sezgisel bir makine öğrenmesi algoritmasıdır(Pathak ve ark, 2018). Temel olarak, veri setini içindeki değişkenlere göre dallara ayırarak ilerleyen bir yapı oluşturur. Bu yapı, bir ağacın dallanma prensibine benzediği için "karar ağacı" olarak adlandırılır. Her bir düğümde bir özellik seçilir ve veri bu özelliğe göre iki veya daha fazla alt kümeye bölünerek bir sonraki aşamaya geçilir. Yaprak düğümler, modelin verdiği nihai kararları veya tahminleri temsil eder. Hava durumunu tahmin etmekte yardımcı olan basit bir karar ağacı Şekil 1.13'de gösterilmiştir




Şekil 1.13. Hava durumunu tahmin etmekte kullanılan basit bir karar ağacı

Karar ağaçları, özellikle yorumlanabilirlik açısından büyük avantaj sağlar. Bir insan, ağacın dallarını takip ederek hangi özelliklerin hangi kararları etkilediğini kolayca anlayabilir. Bu yüzden, özellikle açıklanabilir modellerin önemli olduğu alanlarda tercih edilir. Ancak, karar ağaçlarının en büyük dezavantajlarından biri aşırı öğrenme eğiliminde olmalarıdır(Quinlan, 1986). Regresyon problemlerinde kullanılan karar ağaçları, sürekli (sayısal) bir değer tahmin etmek için kullanılır. Burada, her bölme işleminde veri kümesi belirli eşik değerlerine göre ayrılır ve nihayetinde her yaprak düğümde sürekli bir çıktı üretilir (Scikit-learn, 2025). Örneğin bireylerin yaş, vücut kitle indeksi(BMI) ve insülin seviyesine dayanarak kan şekeri seviyesini tahmin eden bir karar ağacı modeli oluşturulabilir. Model, bu değişkenleri kullanarak veriyi belirli aralıklara böler ve her grup için tahmini bir kan şekeri seviyesi belirler. Karar ağacının dalları, farklı değişkenlere göre sınıflandırmaları gösterirken, yaprak düğümleri belirli bir grup için tahmin edilen kan şekeri seviyesini içerir.

- **Random Forest:**

Birden çok karar ağacının bir araya gelerek oluşturduğu bir topluluk yöntemidir. Model, her bir karar ağacını farklı rastgele örnekler ve özellikler kullanarak oluşturur, bu da aşırı öğrenme azaltır ve genel performansı artırır(Durak ve Hark, 2024). Bu yöntem, verinin çeşitliliğini koruyarak daha dengeli ve genelleştirilebilir bir model oluşturulmasını sağlar. Random Forest, doğruluk oranı yüksek ve aşırı uyuma karşı dayanıklı olduğu için, karmaşık veri setleri için güçlü bir tercihtir. Breiman

(1996) tarafından önerilen bu yöntem, makine öğreniminde yaygın olarak kullanılmaktadır ve sınıflandırma ile regresyon problemlerinde etkili sonuçlar sunmaktadır(Breiman, 2001). Random forest algoritmasına örnek olarak bir hastanın hastaneye yatışından sonraki iyileşme hızının tahmin edilmesi, bu yöntemle gerçekleştirilebilir. Bu tür bir regresyon modelinde, eğitim verisi olarak hastanın yaşı, cinsiyeti, mevcut hastalıkları, tedaviye yönelik aldığı ilaçlar, biyokimyasal test sonuçları, kan basıncı, kalp atış hızı gibi çeşitli klinik parametreler ve sağlık göstergeleri kullanılabilir. Random forest algoritmasındaki karar ağaçlarının her birinde eğitim verisinin rastgele bir alt kümesiyle eğitilir ve farklı özellik kombinasyonlarına dayalı tahminlerde bulunur. Bu ağacın her biri, hastanın iyileşme sürecini etkileyebilecek faktörleri dikkate alarak tahminler yapar. sonunda, her bir ağacın tahminleri birleştirilir ve genel bir tahmin değeri (örneğin, iyileşme oranı) elde edilir. Random forest ile karar ağacı regresyonu arasındaki farkı şekil 1.14’de gösterilmiştir.




Şekil 1.14. Random forest ve karar ağacı

- **Gradient Boosting:**

Gradient Boosting, güçlü bir öğrenici oluşturmak için zayıf öğrenicilerin birleştirildiği iteratif bir süreçtir. Zayıf öğreniciler, örneğin karar ağaçları olabilir (Scikit-learn, 2025). Bu süreç, her adımda hataları azaltarak daha doğru tahminler yapmayı amaçlar. Başlangıç olarak, ilk bir karar ağacı oluşturulur. Bu ağaç, hedef değişkenin gerçek değerleri ile tahmin ettiği değerler arasındaki farkı hesaplar ve bu fark, modelin hata miktarını gösterir. Ardından, ikinci bir ağaç oluşturulur. Bu yeni ağaç, bir önceki ağacın tahmin ettiği hataların negatif gradyanını (yani, hata düzeltilmesini) tahmin etmeye çalışır. Böylece, yeni ağaç, birinci ağacın yaptığı hataları düzeltir ve modelin doğruluğu artar. Bu süreç, her yeni ağacın bir önceki ağacın hata payını minimize etmeye çalışarak

tekrar edilir. Her aşamada model, hataları daha da azaltarak daha güçlü bir öğreniciye dönüşür. Yani, her yeni ağaç, bir önceki adımda yapılan hataları düzeltir ve bu şekilde modelin performansı artar. Bu iterasyonlar, belirli bir sayıya kadar devam eder veya hata seviyesi istenilen düzeye gelene kadar sürer(Friedman, 2001). Gradient Boosting çalışma prensibini Şekil 1.15’de gösterilmiştir.



Şekil 1.15. Gradient boosting çalışma prensibi(Baharvand ve Ahmari, 2024)

- **KNeighbors Regresyon**

KNeighbors, makine öğrenmesinde öncelikle sınıflandırma problemleri için yaygın olarak kullanılan, basit ama etkili bir yöntemdir. Bu yaklaşımda, bir veri noktasının sınıfı, en yakın K komşusunun sınıf etiketlerine göre çoğunluk oylaması yapılarak tahmin edilir. Aynı zamanda KNeighbors algoritması regresyon problemlerinde de kullanılabilir; bu durumda, komşuların çıktı değerlerinin ortalaması alınarak tahmin yapılır. Temelde, benzer girdilerin benzer çıktılar üreteceği varsayımı üzerine kurulu olup, düşük boyutlu veri setlerinde başarılı sonuçlar verebilir(Ortiz-Bejar ve ark 2018). Matematiksel olarak, bir veri noktası x' için KNN regresyon tahmini şu şekilde hesaplanır:

$$f_{knn}(x') = \frac{1}{k} \sum_{i \in N_k(x')} y_i \quad (1.5)$$

Denkleimde:


x' : Tahmin yapmak istediğimiz yeni veri noktasıdır.

$N_k(x')$: x' noktasına en yakın K komşunun indekslerini gösterir.

y_i : En yakın K komşunun gerçek çıktı değerleridir.

$f_{knn}(x2)$: x' için tahmin edilen sonuçtur.

KNN regresyonu çalışırken önce, tahmin edilmek istenen veri noktasına en yakın K adet komşu bulunur. Daha sonra bu komşuların çıktı değerleri alınarak ortalama hesaplanır ve bu değer, yeni veri noktası için tahmin edilen sonuç olarak atanır. K-En Yakın Komşu (KNN) algoritmasında kaç komşunun dikkate alınacağını belirlemek için komşu sayısı parametresi kullanılır. Bu parametre, bir veri noktasının tahmini yapılırken kaç tane en yakın komşunun kullanılacağını kontrol eder. Komşu sayısı 5 olan bir örneğin grafiği şekil 1.16'de gösterilmiştir.




Şekil 1.16. Komşu sayısı 5 olan bir KNeighbors Regresyon örneği

Şekil 1.16'de gösterilen örnekte dikkate alınan 5 komşunun değerleri toplanarak ortalaması hesaplanır. Daha sonra bulunan ortalama, tahmin edilmesi istenen verinin değeri olarak kabul edilir. Büyük veri kümelerinde hesaplama maliyeti yüksek olabilir ve uzak noktalar tahminleri olumsuz etkileyebilir. Bu yüzden, veriyi normalize etmek ve uygun K değerini seçmek performansı artırmak için kritik öneme sahiptir.

- **MLP(Multilayer Perceptron Regressor) Regresyon**

Yapay Sinir Ağları (ANN) temelli bir regresyon modelidir. (MLP), yapay sinir ağı mimarisini kullanarak çalışır. Doğrusal olmayan ve karmaşık ilişkileri modelleyebilme yeteneğine sahiptir. Bu model, en az bir gizli katmana sahip tam bağlantılı bir sinir ağıdır. İlk olarak, giriş katmanına gelen veriler, gizli katmanlardaki nöronlar aracılığıyla işlenir. Her nöron, giriş verilerini belirli ağırlıklarla çarpar, toplar ve aktivasyon fonksiyonuna uygular (Scikit-learn, 2025). Gizli katmanlardan geçen veriler, çıkış katmanında son tahmin değerine ulaşır3 giriş verisi, 2 gizli katmanı ve 2 çıkış verisi olan bir örnek, Şekil 1.17'de gösterilmektedir.



Şekil 1.17. MLP regresyon örneği


MLP Regressor, farklı öğrenme algoritmaları kullanarak ağırlıkları güncelleyerek öğrenmeyi sağlar. Bu modelin performansını belirleyen en önemli faktörlerden biri, gizli katman sayısı ve her katmandaki nöron sayısıdır. Eğer çok az nöron ve katman kullanılırsa model yeterince karmaşık ilişkileri öğrenemez ve düşük performans gösterir. Ancak, çok fazla katman ve nöron kullanılırsa aşırı öğrenme riski artar ve model, sadece eğitim verisini ezberleyerek yeni verilere uyum sağlayamaz.

MLP Regressor'un en büyük avantajlarından biri, karmaşık ilişkileri öğrenebilmesidir. Ayrıca, veri üzerinde belirli varsayımlar yapmadığı için esnek bir modeldir.

- **XGB Regressor**

XGBoost, Gradient Boosting algoritmasını daha hızlı, daha verimli ve aşırı öğrenmeyi önleyici ek özelliklerle geliştiren bir yöntemdir. Geleneksel Gradient Boosting algoritmalarına kıyasla, paralel işlem yeteneği, donanım optimizasyonları ve daha iyi bellek yönetimi sayesinde çok

daha büyük veri setlerinde etkili bir şekilde çalışır. Bunun yanı sıra, L1 ve L2 teknikleriyle aşırı öğrenmeyi önler ve modelin daha iyi genelleşmesini sağlar. XGBoost algoritmasının çalışma presibini Şekil 1.18’de gösterilmiştir.



Şekil 1.18. XGBoost çalışma presibi

Ayrıca, eksik verileri otomatik olarak işleyebilme özelliğine sahiptir ve her ağacın en iyi bölünme noktalarını önceden hesaplayarak daha optimize bir öğrenme süreci sunar. Tüm bu avantajları sayesinde Gradient Boosting'e kıyasla daha iyi performans gösterir(T. Chen ve Guestrin, 2016).

- **AdaBoost Regressor**

AdaBoost (Adaptive Boosting), güçlü bir topluluk öğrenme yöntemidir ve genellikle sınıflandırma problemlerinde kullanılsa da regresyon problemleri için de oldukça etkili bir yöntemdir. AdaBoost'un temeli, zayıf öğrenicilerin birleştirilerek daha güçlü bir model oluşturulmasına dayanır. İlk adımda, veri setine uygun bir zayıf öğrenici (çoğunlukla küçük karar ağaçları veya regresyon ağaçları) eğitilir. Bu model, tahminlerin ortalamasını öğrenir ve ardından hatalar hesaplanarak, hatalı tahminler için daha büyük ağırlıklar atanır. Sonraki adımlarda, her yeni model, önceki modelin hatalarını düzeltmeye odaklanır ve her bir modelin katkısı, doğruluğuna göre belirli bir katsayıya sahip olur. Sonunda, tüm zayıf öğrenicilerin tahminlerinin bir ağırlıklı ortalaması alınarak son tahmin elde edilir. Bu yöntem, hatalı tahminleri düzeltmeye ve modelin doğruluğunu artırmaya yönelik güçlü bir strateji sunar, böylece yüksek performanslı ve genellenebilir bir model elde edilir. çalışır.(Freund ve Schapire, 1997).

- ***Gaussian Process***


Regresyon ve sınıflandırma problemlerinde kullanılan güçlü bir olasılıksal modeldir. GPR, herhangi bir fonksiyonun olasılık dağılımını modelleyerek hem tahmin yapabilme hem de belirsizlik ölçümü sağlayabilme yeteneğine sahiptir. Bu özellik, GP'yi özellikle küçük veri setleriyle çalışırken ve belirsizlik hesaplamalarının kritik olduğu alanlarda değerli kılar. GPR, gözlem noktaları arasındaki ilişkiyi belirlemek için kovaryans fonksiyonları (kernel fonksiyonları) kullanır ve en yaygın kullanılan kernel fonksiyonları arasında Radial Basis Function (RBF), Matérn ve lineer çekirdekler bulunur. Modelin eğitimi sırasında bu kernel fonksiyonlarının parametreleri optimize edilerek en uygun fonksiyon tahmini yapılır. Makine öğrenmesinde GP, klasik doğrusal ve doğrusal olmayan regresyon modellerine alternatif olarak esnek ve açıklanabilir bir yöntem sunar(Rasmussen, 2004).

- ***Bayesian Ridge***

Klasik Ridge regresyonunun olasılıksal istatistik çerçevesinde genişletilmiş bir versiyonudur. Ridge regresyonu, doğrusal regresyon katsayılarını L2 normuyla düzenleyerek aşırı öğrenme önlemeye çalışırken, Bayesian Ridge regresyonu bu düzenlemeyi Bayes teoremi kullanarak olasılıksal bir yaklaşımla gerçekleştirir. Model, regresyon katsayılarının bir ön dağılıma sahip olduğunu varsayar ve bu katsayıların olasılıksal dağılımını güncelleyerek tahminler yapar. Böylece, model karmaşıklığı ve parametreleri, veri setine en uygun şekilde optimize edilir. Bayesian Ridge regresyonunun en önemli avantajlarından biri, hiperparametrelerin otomatik olarak optimize edilmesi sayesinde aşırı öğrenme ve eksik öğrenme risklerini azaltmasıdır. Ayrıca, küçük veri setlerinde Ridge regresyona kıyasla daha iyi genelleştirme yapabilir ve tahminlerine ilişkin belirsizlikleri de hesaplayabilir(MacKay, 1992).

- **Bagging Regressor**

İstatistiksel modellemede ve makine öğrenmesinde, modelin doğruluğunu artırmak amacıyla kullanılan güçlü bir ansamble yöntemidir. Bagging Regresor algoritmasının çalışma prensibini Şekil 1.19'de gösterilmiştir.




Şekil 1.19. Bagging Regresor çalışma prensibi

Regresyon problemlerinde bagging, birden fazla regresyon modelinin birleşimiyle daha güvenilir ve doğru tahminler yapmayı sağlar. Temelde, bagging algoritması, eğitim veri setinden rastgele alt örneklemler alarak birden çok model eğitir ve bu modellerin çıktılarının ortalamasını alarak nihai tahmin elde eder. Bu yöntem, her bir modelin farklı alt küme veriler üzerinde öğrenmesini sağlayarak, modelin genelleme yeteneğini artırır ve aşırı uyum riskini azaltır. Bagging'in en bilinen örneklerinden biri, her biri bağımsız olarak eğitilen karar ağaçlarının kullanıldığı Random Forest algoritmasıdır. Regresyon problemlerinde bagging, hem verinin heterojenliğini daha iyi yansıtarak hem de modelin h(Breiman, 1996a)ata payını minimize ederek daha doğru ve güvenilir tahminler yapmaya olanak tanır. Bu sayede, özellikle gürültülü ve karmaşık verilerle çalışırken bagging, modelin performansını önemli ölçüde iyileştirir (Breiman, 1996).

- **Destek Vektör Makineleri:**

SVM algoritmasının regresyon için uyarlanmış bir versiyonudur. SVM'nin temel amacı, bir fonksiyon öğrenerek verilen giriş değerleri için en iyi tahmini yapmak ve bu tahminlerin belirli bir hata payı içinde kalmasını sağlamaktır. SVR, bir veri kümesinden öğrenilmiş bir karar sınırı oluşturur. Ancak klasik doğrusal regresyon gibi ortalama hatayı minimize etmeye çalışmaz, bunun yerine belirli bir tolerans aralığı (ϵ -tüpü) içinde kalan tahminleri doğru kabul eder. ϵ (epsilon) değeri, tahmin edilen değerlerin gerçek değerlerden ne kadar sapmasına izin verileceğini belirler. Örneğin, eğer $\epsilon = 0.1$ olarak seçildiyse, tahmin edilen değerlerin gerçek değerden en fazla ± 0.1 kadar farklı olmasına izin verilir. Destek vektörleri, modele en yakın olan ve karar sınırını belirleyen veri noktalarıdır. SVM, bu destek vektörleri kullanarak tahmin yapar. Ayrıca, çekirdek fonksiyonları (kernel) sayesinde doğrusal olmayan ilişkileri de öğrenebilir. Örneğin, doğrusal çekirdek (Linear Kernel) veri noktaları doğrusal olarak ayrılabiliriyorsa kullanılırken, polinom çekirdek (Polynomial

Kernel) daha karmaşık yapıları modellemek için uygundur. RBF (Radial Basis Function) çekirdeği ise en yaygın kullanılan çekirdek türüdür ve doğrusal olmayan ilişkileri başarılı bir şekilde yakalayabilir(Breiman, 1996). SVM algoritmasının Şekil 1.20'de gösterilmiştir.



Şekil 1.20. SVM regresyonunun çalışma prensibi

Diğer makine öğrenmesi yöntemlerine değinecek olursak, denetimsiz öğrenme, etiketlenmemiş veriler üzerinde kullanılan bir yaklaşımdır. Bu yöntemde, sınıflandırılmak istenen veri seti modele girdi olarak sunulur ve model, veriler arasındaki benzerlikleri veya yapısal örüntüleri keşfederek sınıflandırma işlemini gerçekleştirir. Böylece, sonradan verilecek test verileri, modelin belirlediği yapıya göre otomatik olarak etiketlenebilir(James ve ark, 2023). Yarı denetimli öğrenme ise az miktarda etiketlenmiş veri ile büyük miktarda etiketsiz veriyi birleştirerek model geliştirmeyi amaçlayan bir tekniktir. Bu yöntem, özellikle etiketleme sürecinin zaman alıcı veya maliyetli olduğu durumlarda etkili sonuçlar verebilmektedir(Gökalp, 2022). Öte yandan, takviyeli öğrenme (reinforcement learning), bir sistemin çevresiyle etkileşimde bulunarak, aldığı geri bildirimler doğrultusunda deneyimlerinden öğrenmesini ve zamanla en uygun stratejiyi geliştirmesini sağlayan bir öğrenme yöntemidir. Bu algoritma, deneme-yanılma ilkesine dayanmakta olup, her eylem sonrasında aldığı ödül veya ceza ile kararlarını sürekli olarak iyileştirme yeteneğine sahiptir(Wiering ve Van Otterlo, 2012).

1.4. Makine Öğrenmesi Model Değerlendirilmesi

Makine öğrenmesi modellerinin performansını değerlendirmek, geliştirilen modelin gerçek dünya verileri üzerindeki başarısını anlamak için kritik öneme sahiptir. Bu değerlendirme, modelin genelleme yeteneğini ve tahminlerinin doğruluğunu ölçmeyi sağlar.

1.4.1. Yöntemler

Bir modelin performansını ölçmek için izlenen süreç veya stratejidir. Verilerin doğru bir şekilde bölünmesi, kullanımı ve modelin genelleme yeteneğinin test edilmesi. Hold-out ve çapraz doğrulama yöntemi en yaygın kullanılan yöntemlerdir.

Hold-out yöntemi

Bu yöntemde veri setini genellikle eğitim seti ve test seti olarak ikiye bölünmektedir(Aladwani ve Elsharkawy, 2023). Veri setinin belirli bir yüzdesi (örneğin %70) modelin eğitimi için kullanılır (eğitim seti). Kalan kısmı (örneğin %30) modelin performansını değerlendirmek için ayrılır (test seti). Eğitim ve test yüzdeleri modelin durumuna göre belirlenmektedir. Eğitim seti kullanılarak model eğitilir. Bu süreçte model, verilerdeki ilişkileri öğrenir. Test seti üzerinde modelin doğruluğu veya hatası ölçülerek performansı değerlendirilir. Test seti daha önce model tarafından görülmediği için genelleme yeteneği bu aşamada değerlendirilir. Bu çalışmada geliştirilen makine öğrenmesi modelini test etmek için yöntemlerden hold-out yöntemi kullanılmıştır.

Çapraz doğrulama

Bu yöntem, veri setinin farklı bölümlerinde modelin test edilmesine olanak tanıyarak, sonuçların veri setine bağımlılığını azaltır ve daha sağlam bir değerlendirme sağlar (Scikit-learn, 2025). Veri setini birden fazla alt gruba (kat) böler ve her bir kat sırasıyla test seti olarak kullanılırken geri kalanı eğitim seti olarak kullanılır. Çapraz doğrulama yönteminin k-fold çapraz doğrulama ve LOOCV GİBİ birden fazla türü vardır.

1.4.2. Metrikler

Makine öğrenmesi modellerinde metrik, bir modelin performansını değerlendirmek için kullanılan ölçüm yöntemidir. Metrikler, modelin tahminlerinin ne kadar doğru olduğunu veya nasıl hata yaptığını sayısal olarak ifade etmektedir. Bu ölçümler, modelin genelleme yeteneğini ve belirli bir problem üzerindeki etkinliğini anlamamıza yardımcı olur. Hataları ve eksiklikleri tespit ederek modeli optimize etmemize olanak sağlamaktadır.

Sınıflandırma problemleri için metrikler

Sınıflandırma problemlerinde tahmin edilen sınıfların doğruluğu ve yanlışlığı değerlendirmek için kullanılmaktadır.

- **Doğruluk :**

Modelin doğru tahmin ettiği örneklerin toplam örnek sayısına oranıdır.

$$\text{Doğruluk} = \frac{\text{Doğru Tahmin Sayısı}}{\text{Toplam Örnek Sayısı}} \quad (1.6)$$

- **Kesinlik:**

Pozitif tahminlerin ne kadarının doğru olduğunu ölçmektedir.

$$\text{Kesinlik} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Pozitif}} \quad (1.7)$$

Duyarlılık:

Gerçek pozitiflerin ne kadarının doğru tahmin edildiğini ölçmektedir.

$$\text{Duyarlılık} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış negatif}} \quad (1.8)$$

- **F-Skoru:**

Kesinlik ve duyarlılık arasındaki dengeyi ölçmektedir.

$$F - \text{Skoru} = 2 \cdot \frac{\text{Kesinlik} \cdot \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (1.9)$$

Regresyon problemleri için metrikler

Regresyon problemlerinde tahmin edilen değerlerin gerçek değerlerle ne kadar uyumlu olduğu değerlendirmektedir.

- **MAE (Mean Absolute Error):**

Makine öğrenmesi ve istatistikte bir tahmin modelinin doğruluğunu ölçmek için kullanılan bir performans metriğidir. MAE, modelin tahmin ettiği değerler ile gerçek değerler arasındaki farkların mutlak değerlerinin ortalamasını alarak hesaplanır. Çalışmada MAE metriği kullanılmıştır.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (1.10)$$

- **MSE (Ortalama Kare Hata) :**

Hataların karelerinin ortalamasına eşittir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (1.5)$$

- **R-Kare(R^2):**

R-kare, verilerin uygun regresyon çizgisine ne kadar yakın olduğunu gösteren istatistiksel bir ölçüdür. Doğrusal bir model tarafından açıklanan bağımlı değişken varyasyonunun yüzdesini ifade eder. R-kare değeri genellikle 0 ile 1 arasında değişir ve değerin 1'e yakın olması, modelin o kadar başarılı olduğunu gösterir.

$$R^2 = 1 - \frac{SS_{RES}}{SS_{TOT}} \quad (1.6)$$

SS-RES : Artık kareler toplamı

SS-TOT : Toplam kareler toplamı

- **RMSE (Ortalama Hataların Kökü):**

MSE'nin kareköküdür ve hataları orijinal biriminde göstermektedir.

$$RMSE = \sqrt{MSE} \quad (1.73)$$

- **Ortalama Mutlak Sapma (MAD)**

MAD, bir veri kümesindeki her bir değer, o veri kümesinin ortalamasına olan mutlak uzaklıklarının ortalamasıdır. Genellikle veri setinin yayılımını ölçmek için kullanılır. Regresyon bağlamında ise, bazı durumlarda MAE'ye çok yakın sonuçlar verdiği için hata değerlendirme metrikleri arasında yer alabilir. Ancak MAE'den farklı olarak tahmin hatalarını değil, gözlemlerin ortalamadan ne kadar saptığını ölçer.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \bar{y}_i| \quad (1.14)$$

Bu çalışmada, makine öğrenmesi yöntemleri kullanılarak EKG ve PPG gibi farklı biyolojik sinyallerden elde edilen özelliklerle kan basıncı tahmini yapılmıştır. Bu yöntem, invaziv olmayan ve sürekli ölçüm sağlama açısından önemli avantajlar sunmaktadır. EKG ve PPG gibi kolayca ölçülebilen sinyaller, kan basıncı ile ilişkili belirli özellikler (örneğin, Pulse Transit Time - PTT)

üzerinden değerlendirilmiştir. Bu veriler, makine öğrenmesi modellerine işlenerek kan basıncı tahmini gerçekleştirilmiştir.

Tasarlanan makine öğrenmesi kodu Python dili ile Spyder IDE üzerinde yazılmıştır. Kodlama sürecinde, öncelikle sinyallerden kullanılacak özellikler hesaplanmış, ardından makine öğrenmesi modeli oluşturulmuştur. Kodu test etmek amacıyla, [UC Irvine Machine Learning Repository] (UCI, 2025) açık erişim veri setlerinden yararlanılmıştır. Model doğruluğu istenen seviyeye ulaştığında, EKG ve PPG sinyalleri için uygun sensörler kullanılarak gerçek veri toplanmaya başlanmıştır.

Çalışmada tasarlanan donanıyla iki ölçüm alınmıştır. İlk ölçüm, dinlenme durumunda 20 dakika boyunca alınmış; ikinci ölçüm ise koşma sırasında, yine 20 dakika süresince gerçekleştirilmiştir.

1.5. Çalışmanın Amacı

Sporcuların performansını değerlendirmek, uygun antrenman programları tasarlamak ve anlık sağlık durumunu takip etmek, antrenörler için büyük önem taşımaktadır. Bir antrenör, sporcunun fiziksel ve fizyolojik durumunu göz önünde bulundurarak, maç sırasında oyuna devam edip edemeyeceğini, sakatlık riskinin olup olmadığını, takım arkadaşlarına veya aynı branştaki diğer sporculara kıyasla performans seviyesini değerlendirebilir. Aynı zamanda, sporcunun mevcut durumuna en uygun ve verimli antrenman programını belirleyebilir ve bu programın uygulanması sırasında gelişiminin nasıl ilerlediğini takip edebilir. Böylece, sporcunun antrenman programına ne kadar uyum sağladığı ya da programın yeterince etkili olup olmadığı gibi kritik sorulara yanıt bulunabilir. Bu tür değerlendirmeler için sporcunun vücudundan elde edilen biyolojik sinyaller önemli bir veri kaynağı olarak kullanılmaktadır. Farklı parametreler incelenerek sporcunun fiziksel durumu hakkında detaylı bilgiler edinilebilir. Bu biyolojik sinyaller, değerlendirilmek istenen duruma göre sporcunun dinlenme anında, antrenman sırasında veya antrenman sonrasında ölçülebilir. Özellikle kan basıncı gibi fizyolojik değişkenler, sporcu sağlığının izlenmesi açısından kritik bir rol oynamaktadır. Bu çalışmada, biyolojik sinyaller aracılığıyla sporcuların kan basıncı değerlerini tahmin etmek amaçlanmaktadır. Yaygın olarak kullanılan klasik ölçüm yöntemlerinin aksine, invaziv olmayan, sürekli, rahat ve uygun maliyetli bir ölçüm yöntemi geliştirilmesi hedeflenmektedir. Bu doğrultuda, sporcunun vücudundan elde edilen Elektrokardiyografi (ECG) ve Fotopletismografi (PPG) sinyalleri analiz edilerek, kan basıncı ile doğrudan ilişkilendirilebilecek parametreler çıkarılacaktır. Daha sonra, bu parametreler kullanılarak tahmin modelleri tasarlanacaktır. Geliştirilecek sistemin, sporcuların hareket halindeyken dahi doğru ve güvenilir ölçümler yapabilmesi büyük bir önem taşımaktadır. Bu nedenle, sistemin sporcunun hareketinden minimum düzeyde etkilenmesi ve vücut üzerindeyken hafif, konforlu ve taşınabilir olması gibi önemli tasarım kriterleri göz önünde bulundurulacaktır. Böylece hem antrenman hem de maç/yarış

sırasında kullanılabilir, sporcuların performanslarını ve sađlık durumlarını anlık olarak deđerlendirmeye yardımcı olacak yenilikçi bir sistem ortaya konulacaktır.



2. ÖNCEKİ ÇALIŞMALAR

Sporcuların performans takibi ve sağlık durumlarının izlenmesinde kan basıncı (KB), en önemli biyofizyolojik parametrelerden biridir. Ancak, geleneksel manşetli kan basıncı ölçüm yöntemleri, sporcular için sürekli ve kesintisiz izleme yapmaya uygun değildir. Bu durum, manşetsiz (manşonsun) ve invaziv olmayan invaziv KB ölçüm yöntemlerine olan ilgiyi artırmıştır.

Son yıllarda, biyosinyal analizi temel alınarak geliştirilen modellerle ECG ve PPG gibi fizyolojik sinyaller kullanılarak KB tahmini yapılması üzerine birçok çalışma gerçekleştirilmiştir. Aşağıda, sporcularda biyosinyal tabanlı kan basıncı tahmini üzerine yapılan önceki çalışmalar özetlenmiştir.

2.1. Makine Öğrenimi Tabanlı Kan Basıncı Tahmin Modelleri

Chen ve arkadaşları (2019), manşetsiz ve invaziv olmayan KB tahmini için makine öğrenimi tabanlı bir model geliştirmiştir. Çalışmada, fotopletizmografi (PPG) ve elektrokardiyografi (ECG) sinyallerinden türetilen Pulse Transit Time (PTT) ve diğer sinyal tabanlı özellikler kullanılmıştır. KB tahmini, birden fazla makine öğrenimi modeli ile gerçekleştirilmiş ve doğruluk açısından optimize edilmiştir. MIMIC-II veri seti üzerinde test edilen model, genetik algoritma ile optimize edilmiş destek vektör regresyonu (GA-SVR) yöntemi ile sistolik kan basıncı (SKB) tahmini için 3.27 ± 5.52 mmHg, diyastolik kan basıncı (DKB) tahmini için ise 1.16 ± 1.97 mmHg hata oranlarıyla en iyi performansı göstermiştir (Chen ve ark, 2019).

Benzer şekilde, Kachuee ve arkadaşları (2015), kalibrasyon gerektirmeyen bir manşetsiz KB tahmin modeli geliştirmiştir. Bu çalışmada, PPG ve ECG sinyallerinden elde edilen PTT özellikleri kullanılarak KB tahmini gerçekleştirilmiştir. PTT'nin KB ile güçlü bir korelasyonu olduğu gösterilmiş olsa da, bireyler arasındaki fizyolojik farklılıklar nedeniyle kişiye özel kalibrasyon gerektirmesi önemli bir dezavantaj olarak görülmektedir. Bu çalışmada, kalibrasyon gerektirmeyen bir model geliştirmek için çeşitli sinyal işleme ve makine öğrenmesi algoritmaları kullanılmıştır. Destek vektör regresyonu (SVR), yapay sinir ağları (ANN) ve düzenlenileştirilmiş doğrusal regresyon (RLR) modelleri ile yapılan analizlerde, SVR tabanlı modelin en iyi performansı sergilediği görülmüş, DKB tahmini için 6.34 ± 8.45 mmHg, SKB tahmini için ise 12.38 ± 16.17 mmHg hata oranları elde edilmiştir (Kachuee ve ark, 2015).

2.2. Fiziksel Aktivite ve Cerrahi Süreçlerde KB Tahmini

Sun ve arkadaşları (2016), fiziksel egzersiz sırasında PPG ve ECG sinyalleri kullanarak SKB tahmini yapan bir model geliştirmiştir. 19 katılımcının verileri analiz edilerek PPG sinyalinin dalga şekli, türevleri, frekans bileşenleri ve Pulse Arrival Time (PAT) gibi 18 farklı özellik çıkarılmıştır. Çalışmada Multiple Linear Regression (MLR) modeli, 0.43 mmHg ortalama farkı, 13.52 mmHg standart sapma ile diğer modellere kıyasla en iyi performansı sergilemiş ve PAT'in eklenmesiyle

tahmin doğruluğunun arttığı gösterilmiştir. Ayrıca, parmak veya alından ölçülen PPG sinyallerinin benzer doğrulukta sonuçlar verdiği, ancak vücut duruşunun tahmin doğruluğunu etkilediği gözlemlenmiştir(Sun ve ark, 2016).

Shaoxiong Sun ve arkadaşları (2023), cerrahi operasyonlar sırasında sistolik kan basıncı (SKB) tahmini için invaziv olmayan bir yöntem geliştirmiştir. Çalışmada, pulse arrival time (PAT), PPG genliği, nabız gecikmesi (pulse delay - PD) ve ikinci türev tabanlı morfolojik oranlar olan c/a ve e/a gibi hemodinamik özellikler kullanılarak çoklu doğrusal regresyon modeli ile tahmin yapılmıştır. c/a oranı, PPG sinyalinin ikinci türevinde yer alan c dalgasının genliğinin a dalgası genliğine oranı olarak tanımlanırken, e/a oranı, e dalgasının genliğinin a dalgası genliğine oranı şeklinde ifade edilmiştir. Bu oranlar, damar esnekliği ve kardiyovasküler sistemin durumuna ilişkin dolaylı bilgiler sağlamaktadır. 29 cerrahi hasta üzerinde yapılan testlerde, ortalama fark (MD) = 0.08 mmHg, standart sapma (SD) = 7.97 mmHg ve korelasyon katsayısı = 0.89 olarak hesaplanmış ve modelin Association for the Advancement of Medical Instrumentation (AAMI) standardını karşıladığı belirlenmiştir.(Sun ve ark., 2023)

2.3. Gerçek Dünya Uygulamaları ve Giyilebilir Cihazlar ile KB Tahmini

Wong ve arkadaşları (2023), gerçek dünya koşullarında ECG ve PPG sinyalleriyle KB tahmini için çeşitli makine öğrenimi modellerini karşılaştırmıştır. Çalışmada SKB için SVR modeli, 6.97 mmHg'lik ortalama mutlak hata (MAE) ile en iyi performansı göstermiş ve bu sonuç, İngiliz Hipertansiyon Derneği'nin C sınıfı kriterlerine uygun bulunmuştur (Wong ve ark., 2023)

Choi ve arkadaşları (2023), gerçek zamanlı, manşetsiz bir KB ölçüm cihazı geliştirmiştir. Bu cihaz, ECG elektrotları ve bir mikrofon kullanarak Pulse Transit Time (PTT) yöntemiyle KB tahmini yapmaktadır. Deneylerde, cihaz SKB için 2.72 ± 3.42 mmHg, DKB için ise 2.29 ± 3.53 mmHg ortalama mutlak hata (MAE) ile yüksek doğruluk sağlamıştır(Wong,ve ark, 2023).

Son olarak, Henry ve arkadaşları (2024), manşonsuz kan basıncı (KB) ölçüm sistemlerinin klinik uygulamadaki potansiyelini, avantajlarını ve karşılaşılan zorlukları detaylı bir şekilde incelemiştir. Çalışmada, fotopletismografi (PPG), tonometri ve elektrokardiyografi (ECG) sinyalleri kullanılarak KB tahmini yapan sistemler analiz edilmiştir. Özellikle sinyal işleme tekniklerinin ölçüm doğruluğu üzerindeki kritik rolü vurgulanmış; hareket artefaktları ve çevresel faktörlerin ölçüm hatalarına neden olduğu belirtilmiştir. Ayrıca, kalibrasyon ihtiyacı, standart eksikliği ve doğrulama problemleri gibi teknik sınırlamaların giderilmesi gerektiği ifade edilmiştir. Bu çalışmanın 2024 yılına ait güncel bir inceleme olması, literatürde hâlâ çözüm bekleyen pek çok problemin varlığını ortaya koymaktadır. Bu bağlamda, tarafımızdan geliştirilen sistemin kalibrasyon gerektirmemesi, ileride gerçek zamanlı bir yapıya dönüştürülebilmesi ve fiziksel aktivite sırasında dahi güvenilir veri sağlayabilmesi; güncel sorunlara çözüm sunan yenilikçi bir yaklaşım olarak önemini artırmaktadır.

2.4. Genel Değerlendirme

Yapılan önceki çalışmalar, manşonsuz KB tahmini için çeşitli biyosinyal tabanlı yaklaşımlar ve makine öğrenmesi modelleri önermiştir. Ancak bu çalışmaların büyük çoğunluğu kişiye özel kalibrasyon gerektiren sistemlere odaklanmış ve genellikle önceden kaydedilmiş verilerle sınırlandırılmıştır. Ayrıca, mevcut yöntemlerin önemli bir bölümü gerçek zamanlı sistem tasarımına doğrudan uyulanabilir özellikler kullanmamaktadır.

Bu çalışmada ise kalibrasyon gerektirmeyen bir KB tahmin modeli geliştirilmiş ve gerçek zamanlı sistem tasarımı için ön hazırlık niteliğinde bir altyapı oluşturulmuştur. Literatürdeki birçok makine öğrenmesi modeli, anlık olarak çıkarılması zor veya karmaşık sinyal işleme gerektiren parametrelere dayanırken, bu çalışmada gerçek zamanlı olarak kolayca elde edilebilecek ve yorumlanabilir özellikler kullanılmıştır.

Ayrıca, bu çalışmanın ayırt edici bir yönü, verilerin özel olarak tasarlanmış bir donanım aracılığıyla doğrudan toplanmış olmasıdır. Deneklerin spor esnasında ölçüm alımı yapılması, sistemin sporculara özel şekilde optimize edilmesini sağlamış ve fiziksel aktivite sırasında dahi doğru tahminler yapılmasına olanak tanımıştır.

Sonuç olarak, önerilen sistem; kalibrasyon gerektirmeyen, gerçek zamanlı analiz için uygun ve sporcuların anlık kan basıncı değişimlerini güvenilir şekilde izleyebilen bir model olarak öne çıkmaktadır. Bu yönleriyle çalışma, literatürdeki mevcut yaklaşımlara kıyasla önemli avantajlar sunmakta ve alana katkı sağlamaktadır.



3. MATERYAL VE METOT

3.1. Donanım

Gerçekleştirilen çalışmada donanım olarak, sporcudan ölçülen verileri toplamak için M5 Stack Core2 mikrokontrolcüsü, EKG sinyali ölçmek için M5 Stack ECG Module 13.2, PPG sinyali ölçmek için M5 Stack Heart Rate Unit ve sporcudan toplanan verileri arayüze aktarmak üzere Stamp-S3 mikrokontrolcüsü kullanılmıştır. Verileri sporcu üstündeki donanım kısmından arayüze aktarmak için ESP-NOW iletişim protokolü kullanılmıştır.


Sistem diyagramı şekil 3.1.'de gösterilmiştir.



Şekil 3.1. Sistem diyagramı

3.1.1. M5 Stack ECG Module 13.2

EKG sinyali ölçümü yapmayı sağlayan bir modüldür. Bu modül, özellikle Biyosinyal toplama, analiz etme ve sağlık izleme uygulamaları için tasarlanmıştır (M5Stack, 2025). Gömülü sistemlerle kolay entegrasyonu ve taşınabilirliği sayesinde tercih edilmiştir. Modül şeması Şekil 3.2.'de gösterilmiştir.



Şekil 3.2. ECG modül şeması

Modülde sensör olarak modülün ön tarafında yer alan AD8232 Tek Kanallı KAH İzleme sensörü bulunmaktadır. Toplanan sinyaller, AD8603 Düşük Geçirgen Filtre ile işlenerek yüksek frekanslı gürültüleri temizlemektedir ve daha temiz bir sinyal elde edilmesinde yardımcı olmaktadır. İşlenmiş analog sinyaller, AD7476 (10 bit) ADC tarafından dijital forma dönüştürülmektedir. Bu dijital veriler, STM32 mikrodenetleyicisine iletilerek sinyal analizi gerçekleştirilir ve kalp atış hızı istatistikleri oluşturulur. ECG 13.2 modülü, Core2'nin UART portu üzerinden bağlanır ve seri iletişim yoluyla işlenmiş ECG verilerini Core2'ye aktarmaktadır. M5 Stack ECG Module 13.2 teknik özellikleri çizelge3.1.'de gösterilmiştir (M5Stack, 2025).

Çizelge 3.1. ECG modül teknik özellikleri

İletişim Protokolü	UART 115200 bps
AD8232	Yüksek sinyal kazancı: G=100 DC sinyali bloklama özelliği Ortak Mod Bastırma Oranı: 80 dB (DC - 60 Hz arası)
AD7476	10 bit ADC SPI Hızlı veri akış hızı: 1 MSPS Referans voltajı: 2.8 V
Net Ağırlık	18 g
Brüt Ağırlık	101g
Ürün Boyutları	54 mm x 54 mm x 13.2 mm

Modülün kullanma şekli:

Modül, genellikle üç elektrot ile çalışır (bir referans elektrot, bir sağ kol elektrodu ve bir sol kol elektrodu). Bu elektrotlar, vücuda bağlanarak kalp atışlarını ölçer.

3.1.2. M5 Stack Heart Rate Unit

Modül MAX30100 sensörü kullanarak tasarlanmıştır. MAX30100, giyilebilir cihazlarda kullanılmak üzere tasarlanmış, optik tabanlı bir KAH ve oksimetri sensörüdür. Bu sensör, kullanıcının kan dolaşımındaki değişiklikleri ölçerek kalp atış hızını hesaplamaktadır. İletişim için I2C protokolü kullanılmaktadır. SDA ve SCL pinlerini kullanılacak mikrodenetleyiciye bağlanmaktadır.

Modülün kullanma şekli:

Kullanıcının parmağı, sensörün üzerinde doğru şekilde yerleştirilmelidir. Sensör, deri altındaki kan akışını ölçerek kalp atış hızını hesaplamaktadır. Teknik özellikleri çizelge 3.2.'da gösterilmiştir (M5Stack, 2025).

Çizelge 3.2. M5 Stack Heart Rate Unit teknik özellikleri


İletişim Protokolü	I2C: 0x57
Net Ağırlık	5g
Brüt ağırlık	18g
Ürün boyutu	32x24x8mm

Modülün şeması şekil 3.3.'de gösterilmiştir.

Çizelge 3.3. M5Stack Core2 teknik özellikleri

İşlemci: ESP32-D0WDQ6-V3	240 MHz çift çekirdek, 600 DMIPS, 520 KB SRAM, Wi-Fi destekli
Flash Bellek	16 MB
PSRAM	8MB
Giriş Voltajı	5V @ 500mA
Arayüzler	TypeC x 1, GROVE(I2C+I/O+UART) x 1
Ekran	2.0 inç IPS LCD, 320x240 çözünürlük (ILI9342C)
Dokunmatik Ekran	FT6336U
Hoparlör	1W (NS4168)
LED	Yeşil güç göstergesi ışığı
Düğmeler	Güç düğmesi, Sıfırlama (RST) düğmesi, 3 adet sanal ekran düğmesi
Titreşim Hatırlatıcısı	Titreşim motoru
Mikrofon	SPM1423
I2S Güç Amplifikatörü	NS4168
6 Eksenli IMU Sensörü	MPU6886
Gerçek Zamanlı Saat (RTC)	BM8563
Güç Yönetim Ünitesi (PMU)	AXP192
USB Çipi	CH9102F
DC-DC Yükseltici	SY7088
TF Kart Yuvası	Maksimum 16 GB destekler
Lityum Pil	500 mAh @ 3.7V
Anten	2.4G 3D anten
Çalışma Sıcaklığı	0°C ile 60°C arası
Kasa Malzemesi	Plastik (PC)
Ürün Boyutları	54 x 54 x 16.5 mm
Ürün Ağırlığı	54.8 g

M5Stack ECG Module, M5Stack Heart RateUnit ve m5Stack Core2'den oluşan sporcu üstündeki donanım Şekil 3.3'de gösterilmiştir.



Şekil 3.4. Sporcu üstündeki donanım

Şekilde gösterildiği üzere 1 olarak işaretlenmiş donanım M5 Stack Core2 modülü, 2 olarak işaretlenmiş donanım M5 Stack ECG Module 13.2 modülü ve 3 olarak işaretlenmiş donanım M5 Stack Heart Rate Unit modülüdür. Donanımın sporcu üstüne takılmış hali şekil3.4'de gösterilmiştir.



Şekil 3.5. Donanımın sporcu üstündeki hali

Şekilde işaretlendiği gibi sporcunun hareketlerini kısıtlamamak amacıyla geliştirilen donanım sporcunun cebine sığacak büyüklükte tasarlanmıştır.


3.1.4. STAMP-S3

IoT uygulamaları için tasarlanmış, yüksek entegrasyona sahip bir gömülü kontrolör modülüdür. Espressif'in ESP32-S3FN8 ana kontrol çipini kullanan bu modül, 8 MB SPI flash belleğiyle donatılmıştır. Yüksek performanslı Xtensa 32-bit LX7 çift çekirdekli işlemcisi sayesinde 240 MHz'e kadar işlem frekansı sunarak etkileyici bir işlem gücü sağlar. IoT projelerinde ihtiyaç duyulan gömülü kontrol modüllerinin gereksinimlerini karşılamak için özel olarak geliştirilmiştir. STAMPS3, 5V'tan 3.3V'a entegre bir devreyle sabit bir güç kaynağı sağlayarak güvenilir bir çalışma performansı sunar. Ayrıca, programlanabilir bir buton ve RGB durum göstergesi gibi kullanıcı dostu özelliklere sahiptir. ESP32-S3'ün 23 GPIO'sunu modül üzerinden erişilebilir hale getiren STAMPS3, genişletilebilirlik açısından zengin seçenekler sunar. Bu GPIO'lara 1.27 mm/2.54 mm aralıklı bağlantı noktaları aracılığıyla erişilebilir ve SMT, DIP sırası veya uçuş kablosu bağlantıları gibi çeşitli yöntemlerle kullanılabilir. Kompakt bir tasarıma sahip olan modül, güçlü performansı, genişletilebilir IO seçenekleri ve düşük güç tüketimiyle dikkat çeker. STAMPS3, IoT uygulamaları için gömülü kontrolör entegrasyonu gereken senaryolar için ideal bir tercihtir. Kompakt boyutu ve güçlü özellikleri sayesinde geniş projelere uygun olan modül, güvenilir performans ve esnek genişletme seçenekleri sunmaktadır (M5Stack, 2025). STAMP-S3 teknik özellikleri çizelge 3.4'te gösterilmiştir.

Çizelge 3.4. STAMP-S3 teknik özellikleri


MCU	ESP32-S3FN8
DCDC	Yüksek Entegre MUN3CAD01-SC
Flash bellek	8 MB
Giriş Voltajı	5V
Etkileşim	Programlanabilir fiziksel düğme x 1, Programlanabilir RGB LED (WS2812B-2020) x 1
Anten Tipi	2.4G 3D anten
Modül Kaynak Arayüzü	Dokunmatik sensör, SD/SDIO/MMC ana denetleyici, SPI, SDIO/SPI köle denetleyici, EMAC, motor PWM, LED PWM, UART, I2C, I2S, GPIO, darbe sayacı
IO Arayüzü x23	G0/G1/G2/G3/G4/G5/G6/G7/G8/G9/G10/G11/G12/G13/G14 /G15/G39/G40/G41/G42/G43/G44/G46
Bağlantı Yöntemi	SMT/DIP (2.54mm ve 1.27mm aralıklı)/Ara Kablosu
OI Arayüz	2.54mm ve 1.27mm
LCD Arayüz Aralığı	0.5mm@12pin veya 8pin
Çalışma Sıcaklığı	0°C - 40°C
Ürün Boyutu	26mm × 18mm × 4.6mm
Ürün Ağırlığı	3.2g

Modülün şeması şekil 3.6. 'da gösterilmiştir.



Şekil 3.6. STAMP-S3 şeması

Bilgisayara bağlı olan STAMP-S3 şekil 3.7.'de gösterilmiştir.



Şekil 3.7. Bilgisayara bağlı STAMP-S3

3.2. Verilerin ESP-NOW Kablosuz İletişim Protokolü İle Merkez Donanımına Aktarılması

ESP-NOW Espressif firmasının ürettiği ESP32 kartları için kullanılan düşük güçte çalışan kablosuz haberleşme protokolüdür. ESP-NOW kullanılmasıyla farklı bir RF modülüne ya da Wi-Fi modeme ihtiyaç duymadan mikrokontrolcüler arası yüksek hızda iletişim sağlanabilecektir. Veri alışverişi gerçekleştirmek için öncelikle bağlanılacak ESP32 mikrokontrolcüler arasında eşleşme yapılması gerekmektedir. Eşleşme gerçekleştirilirken ESP-NOW iletişim protokolünde veri iletim yönünü belirlenmektedir. ESP-NOW'da veriler sender olarak isimlendirilen ESP32 mikrokontrolcüsünden receiver olarak isimlendirilen mikrokontrolcüsüne gönderilmektedir. sender mikrokontrolcüsüne receiver'ı belirtmek için her ESP32 mikrokontrolcüsünde farklı olan receiver'ın MAC adresini verilmektedir. Mikrokontrolcüler arasındaki eşleşmeyi gerçekleştirildikten sonra veri iletilmesi sağlanmaktadır. One-way ve two-way olmak üzere ESP-NOW protokolünün 2 tane iletim tipi vardır. One-way iletim tipinde veri alışverişi one-to-many veya many-to-one olarak sağlanabilmektedir. One-to-many tipinde bir tane göndericiden birden fazla alıcıya veri iletilirken many-to-one iletim tipinde birden fazla göndericiden bir alıcıya veri iletilmektedir. ESP-NOW'un ikinci iletim tipi olan two-way iletim tipinde ise her ESP32 mikrokontrolcüsü hem gönderici hem de alıcı olarak çalışabilmektedir. Böylece her ESP32 veri gönderebilmesi gibi veri alabilmektedir. ESP32 mikrokontrolcüler arasında her veri paketi için 250 byte'a kadar veri gönderebilmektedir. oluşturulan veri iletim ağında en fazla 20 tane ESP32 mikrokontrolcüsü bulunabilmektedir. tasarlanan sistemde iletim tipinden one-way tipini kullanılmakta olup veriler mobil noktalardaki(sporcu üstündeki) göndericilerden toplanan ECG ve PPG sinyal verilerini merkez olarak isimlendirilen alıcıya many-to-one olarak gönderilmektedir. Bu iletişim protokolü sayesinde sensörlerden ölçülen ve Core2'de toplanan verileri kablosuz bir şekilde çalışmanın yazılımı içeren bilgisayara bağlı olan STAMP-S3 modülüne aktarılmaktadır. Ayrıca bu yöntemle sonraki çalışmalarda birden fazla sporcudan verilerin aynı anda alınması da mümkün olacaktır. ESP-NOW ile diğer kablosuz iletişim protokolleri değerlendirme çizelge 3.5.'da gösterilmektedir.

Çizelge 3.5. ESP-NOW ile diğer kablosun iletişim protokolleri arasında karşılaştırma tablosu

Variable	Wi-Fi	Bluetooth	ESP-NOW
Frequency	2.4 GHz & 5 GHz	2.4GHz	2.4 GHz
Data Rate	54 Mbps	~784 Kbps	1 Mbps
Maximum Range	100 meters	60 meters	~220 meters
Maximum Payload	2312 Bytes	251 Bytes	250 Bytes
Latency For 1 Byte of data at a distance of 1 meter	3.3 ms	6 ms	1 ms
power usage(transmitting data as a transmitter)	538 mW	441 mW	1042 mW

3.3. Yazılım

3.4. Makine Öğrenmesi Kodu

Sensörlerden ölçülen ECG ve PPG sinyalleri Core2’de toplanıp makine öğrenmesi kodu içeren bilgisayara bağlı olan STAMPS3’e gönderilmiştir. Makine öğrenmesi kodu yardımıyla gelen sinyal verilere ilk olarak filtre işlemi gerçekleştirilmiştir. İkinci olarak filtrelenmiş bu sinyallerden uygun metotlar kullanarak kan basıncı tahmininde yardımcı olabilecek özellikler çıkarılmıştır. Çıkarılan bu özellikler sayesinde regresyon modelleri eğitilmiş ve kan basıncı değerleri tahmini yapılmıştır.

3.4.1. Sinyallerin Filtrelenmesi İşlemi

ECG sinyalinin istenmeyen düşük ve yüksek frekans bileşenlerinden arındırılması amacıyla band geçiş filtresi uygulanmıştır. Bu işlemde, Butterworth filtresi tercih edilmiştir ve beşinci dereceden bir filtre tasarlanmıştır. Filtrenin alt kesim frekansı 1.5 Hz, üst kesim frekansı ise 12 Hz olarak belirlenmiştir. Kesim frekansları, örnekleme frekansının Nyquist frekansı ile normalize edilmiştir. Bu filtreleme işlemi, hem düşük frekanstaki drift bileşenlerini hem de yüksek frekanstaki parazitik gürültüleri bastırarak, ECG sinyalinin daha temiz bir biçimde işlenmesini sağlamıştır.

ECG sinyaline benzer şekilde, PPG sinyali de düşük frekanstaki driftler ve yüksek frekanstaki gürültülerden arındırılmıştır. Bu amaçla, PPG sinyali için dördüncü dereceden bir Butterworth band geçiş filtresi uygulanmıştır. Bu filtrede, alt kesim frekansı 0.5 Hz ve üst kesim

frekansı 20 Hz olarak seçilmiştir. Kesim frekansları, örnekleme frekansının Nyquist frekansı ile normalize edilerek ayarlanmıştır. Bu sayede, PPG sinyalinin istenmeyen frekans bileşenlerinden arındırılması ve analiz için daha uygun bir hale getirilmesi sağlanmıştır.

Filtreleme işlemleri sırasında hem ECG hem de PPG sinyalleri için Python programlama dili kullanılmıştır. Scipy.signal kütüphanesi, filtre tasarımı ve uygulanmasında temel araç olarak kullanılmıştır. Özellikle, Butterworth filtre tasarımı için butter fonksiyonu, filtre uygulaması için ise faz kayması yaratmayan filtfilt fonksiyonu tercih edilmiştir. Bu yöntemler, her iki sinyalin daha güvenilir bir şekilde analiz edilmesine olanak tanımıştır.

3.4.2. Özellik Çıkarma İşlemi

İlk başta literatürdeki çalışmalara bakarak olabildiğince çok sayıda özellik çıkarılmıştır. Çıkarılan özellikler; ECG sinyali, PPG sinyali ve sinyallerinin birlikte analiz edilmesiyle türetilen özellikler hesaplanmıştır. İkinci olarak hesaplanan özelliklerden kan basıncı tahmini için önemlilik açısından etkili özellikleri bulmak için özellik çıkarma işlemi gerçekleştirilmiştir. Özellik çıkarma işlemi; veri kümesindeki girdiler arasından modelin performansını artırmak için en anlamlı ve tahmin gücü yüksek olan özelliklerin belirlenmesi sürecidir. Bu işlem, modelin doğruluğunu artırırken aşırı öğrenmeyi azaltır ve aynı zamanda hesaplama maliyetlerini düşürerek modeli daha verimli hale getirir. Özellik seçimi, özellikle büyük veri kümelerinde veya yüksek boyutlu özellik uzaylarında önemli bir rol oynamaktadır.

Özellik Seçiminin Faydaları:

- Aşırı Öğrenmenin Önlenmesi: Gereksiz veya gürültülü özellikler modelin aşırı karmaşık hale gelmesine neden olabilir. Özellik seçimi bunu engeller.
- Modelin Performansını Artırma: Daha az ancak daha anlamlı özelliklerle model daha iyi genelleme yapar.
- Hesaplama Maliyetlerini Azaltma: Daha az özellik ile eğitim ve tahmin süreçleri daha hızlı gerçekleştirilir.
- Yorumlanabilirliği Artırma: Az sayıda özellik ile modelin çıktıları daha kolay anlaşılabilir hale gelir.

Makine öğrenmesi projelerinde özellik seçimi, veri ön işleme ve model geliştirme süreçlerinin kritik bir adımıdır. Özellikle gerçek zamanlı uygulamalarda, yalnızca hesaplama maliyeti düşük ve anlamlı özelliklerin seçilmesi, sistemin etkinliğini artırmada belirleyici bir faktördür. Bu çalışmada Özellik Seçimi için RFE (Recursive Feature Elimination) yöntemi kullanılmıştır.

Recursive Feature Elimination (RFE) Yöntemi:

RFE, makine öğrenmesinde etkili bir özellik seçimi yöntemidir. Bu yöntem, bir tahmin modeli kullanarak her bir özelliğin önemini değerlendirir ve iteratif bir süreçle en az katkı sağlayan özellikleri aşamalı olarak çıkarır. Amaç, model performansını optimize edecek en etkili özellikler grubunu belirlemektir. RFE, özelliklerin model üzerindeki etkisini dikkate alarak, gereksiz verileri elimine eder ve daha güçlü, daha genelleştirilebilir bir model oluşturulmasını sağlamaktadır.

RFE'nin Çalışma Mantığı:

1. Model Eğitim:

Belirli bir temel tahmin edici (örneğin, lineer regresyon, destek vektör makineleri gibi) ile tüm özellikler kullanılarak bir model eğitilir.

2. Özelliklerin Değerlendirilmesi:

Model, her bir özelliğin önemini veya katkısını değerlendirir. Bu değerlendirme, modelin ağırlıklarına veya önem skorlarına dayanır.

3. Özelliklerin Eliminasyonu:

En az katkı sağlayan bir veya daha fazla özellik iterasyonla veri kümesinden çıkarılır.

4. Tekrar:

Kalan özelliklerle süreç tekrar edilir. Bu işlem, belirli bir özellik sayısına ulaşılan kadar veya kullanıcı tarafından belirlenen bir durdurma kriterine kadar devam eder.

5. Sonuç:

Nihai olarak, belirlenen özellikler, model performansını optimize eden alt küme olarak seçilir.

Bu çalışma, gerçek zamanlı bir sistem tasarlamaya hedeflendiği için mümkün olabildiğince az sayıda özellikten yüksek doğrulukta bir kod geliştirmeye planlanmıştır.

Çalışmada seçilen özellikler:

ECG Sinyalinden:

- HR

Bir dakikada atılan kalp atışı sayısını ifade eder ve bpm (beats per minute - dakika başına vuruş) birimiyle ölçülür. Kan basıncı tahmininde kalp hızının (HR) önemi büyüktür. Literatürde, kalp hızının kan basıncıyla doğrudan bir ilişki içinde olduğu ve bu ilişkinin kan basıncı tahmin modellerini iyileştirebileceği gösterilmiştir. Kan basıncı düştüğünde, vücudun otonom sinir sistemi devreye girer ve kalp hızını artırarak kardiyak debiyi yükseltir; bu da arteriyel duvarların kasılmasına yol açarak kan basıncını düzenler. Bu negatif geri besleme mekanizması, kan basıncının hem kalp hızı hem de önceki kan basıncı tahmini ile ilişkili olduğunu ortaya koymaktadır(Wang ve ark, 2014).

- P-R İnterval

PR intervali (PR), atriyal ve atriyoventriküler (AV) nodal iletimi yansıtan bir elektrokardiyografi (EKG) ölçümüdür. Normalde 120-200 ms arasında olan PRi'nin uzaması, kardiyovasküler hastalıklar ve olumsuz sonuçlarla ilişkilendirilmiştir(Husby ve ark., 2015).

PRi'nin kan basıncı tahminiyle doğrudan bir ilişkisi olduğuna dair çok sayıda çalışma bulunmamaktadır. Ancak, PRi'nin uzaması sol ventrikül (LV) kütlesi ve hacmindeki artışlarla ilişkilendirilmiştir. Bu durum, kalbin kan pompalama kapasitesini etkileyerek hemodinamik değişikliklere yol açabilir(T. Chen ve Guestrin, 2016). Ayrıca, PRi'nin uzaması atriyal fibrilasyon ve kalp yetmezliği gibi kardiyovasküler olayların riskini artırabilir. Bu tür ritim bozuklukları ve kalp fonksiyonlarındaki değişiklikler, kan basıncı düzenlemesini etkileyebilir.(Magnani ve ark., 2013)

- R-R İnterval

Ardışık kalp atımları arasındaki süreyi temsil eden bir ölçümdür ve kalp hızı değişkenliği (HRV) analizinde kullanılır. RR ile kan basıncı arasındaki ilişkiyi inceleyen çalışmalar, kardiyovasküler sistemin düzenlenmesinde birlikte rol oynadığını göstermektedir. "Mechanism of blood pressure and R-R variability: insights from ganglion blockade in humans" başlıklı çalışma, R-R aralığı (RRI) ile kan basıncı değişkenliklerinin otonom sinir sistemi tarafından nasıl kontrol edildiğini incelemiştir. Bu araştırmada, ganglion blokajı uygulanan bireylerde RRI ve kan basıncı değişkenliklerinin frekans analizi yapılmıştır. Sonuçlara göre, düşük frekanslı değişimler sempatik sinir sistemi, yüksek frekanslı değişimler ise parasempatik sinir sistemi ile ilişkilidir. Çalışma, RRI ile kan basıncı arasındaki ilişkinin otonom sinir sistemi tarafından düzenlendiğini göstermektedir(Zhang ve ark., 2002). Ayrıca, "A correlation study of beat-to-beat R-R intervals and pulse arrival time during dynamic blood pressure changes" başlıklı çalışma, RRI ve nabız varış zamanı (PAT) arasındaki ilişkiyi incelemiştir. Bu çalışmada, RRI ve PAT arasındaki korelasyonun kan basıncı tahmininde kullanılabileceği önerilmiştir. Sonuçlar, RRI ve PAT'nin birlikte değerlendirilmesinin kan basıncı tahmin modellerinin doğruluğunu artırabileceğini göstermektedir(Peng,ve ark, 2021). Bu çalışmalar, RR'nin kan basıncı tahmininde potansiyel bir gösterge olabileceğini ve otonom sinir sistemi aktivitesinin değerlendirilmesinde önemli bir rol oynadığını göstermektedir.

- P Amplitude

P dalgası, atriyal depolarizasyonu temsil eden EKG'nin ilk dalgasıdır. P dalgasının genliği (P amplitude), atriyumların elektriksel aktivitesinin gücünü ve atriyal iletim yollarının durumunu yansıtır. Literatürde, P dalga genliğindeki değişikliklerin kardiyak output, atriyal hipertrofi ve atriyal iletim bozuklukları gibi kardiyovasküler faktörlerle ilişkili olduğu belirtilmiştir. Bu özellik, kan basıncı düzenlemesini etkileyen otonom sinir sistemi aktivitelerinin bir göstergesi olabileceği için modelde yer almıştır.

- R Amplitude:

R dalgası, ventriküler depolarizasyonun en yüksek noktasını temsil eder ve kalbin en güçlü elektriksel aktivitesini yansıtır. R amplitude, ventriküler kasılma gücüyle ilişkilidir ve bu, dolaylı olarak kardiyak output ve kan basıncıyla bağlantılıdır. Daha yüksek R dalga genlikleri genellikle güçlü ventriküler kasılmaları ifade ederken, genlikteki azalmalar ventriküler fonksiyon bozukluklarını gösterebilir. Kan basıncının ventriküler kasılma gücünden doğrudan etkilendiği düşünüldüğünde, R amplitude önemli bir tahmin değişkeni olarak kullanılmıştır.

- T Amplitude:

T dalgası, ventriküllerin repolarizasyonunu temsil eder ve ventriküler iyileşme sürecinin bir göstergesidir. T amplitude, ventriküler repolarizasyonun büyüklüğünü ve hızını yansıtır. Literatürde, T dalgası özelliklerinin kardiyak stres, elektrolit dengesi ve kan basıncıyla ilişkili olduğu bildirilmiştir. Bu nedenle, T amplitude, ventriküllerin elektriksel stabilitesinin bir göstergesi olarak modelde yer almıştır ve kan basıncı tahmininde yardımcı olabileceği öngörülmüştür.

PPG Sinyalinden:

- PPI:

PPG sinyalindeki ardışık nabız zirveleri arasındaki süreyi temsil eder. PPI, kalp hızına dolaylı olarak bağlıdır ve otonom sinir sistemi düzenlemelerinin bir göstergesidir. Daha kısa PPI süreleri artan sempatik aktiviteyi, daha uzun süreler ise parasempatik baskınlığı işaret eder. Bu özelliğin kan basıncıyla ilişkisi, kalp atım hızı ile kan basıncı arasındaki negatif geri besleme mekanizmasından kaynaklanır(Allen, 2007).

- Sistolik tepe enliği

PPG sinyalindeki sistolik zirvenin genliğini ifade eder. Bu genlik, arteriyel basınç dalgasının büyüklüğünü ve damarların elastikiyetini yansıtır. Daha yüksek genlikler genellikle düşük arteriyel direnç veya genişleyebilir arter duvarlarına işaret ederken, düşük genlikler artan periferik damar direncini gösterebilir. Kan basıncı tahmininde önemli bir değişken olarak kullanılır(Teng ve Zhang, 2003).

- OFF

PPG sinyalinde her atımın bitiş noktasını temsil eden OFF, nabız dalgasının sistolik ve diyastolik bölümlerinin ayrımını yapar. Bu özellik, kalp atımının sonunda damar duvarlarına yayılan basınç dalgasının tamamlanmasını ifade eder. Atım bitiş, arteriyel elastisite, kan akışı ve periferik vasküler direnç gibi hemodinamik parametrelerle ilişkilidir. Özellikle, OFF noktasının zamanlaması ve genliği, kalp-damar sistemi üzerindeki yük ve arteriyel uyumu değerlendirmek için

kullanılabilir. Bu nedenle, PPG sinyalindeki OFF özelliği, kan basıncının tahmini için değerli bir değişkendir.


- B/A Oranı

Dikrotik çentiğın genliğı (b) ile sistolik zirvenin genliğı (a) arasındaki orandır. B/A oranı, damar duvarının elastikiyeti ve arteriyel tonus ile ilişkilidir. Daha yüksek bir b/a oranı, arteriyel sertlikte bir artışa ve periferik damar direncinin yükselmesine işaret eder. Bu özellik, arteriyel sertlikten kaynaklanan kan basıncı değışikliklerini anlamak için önemlidir(Takazawa ve ark., 1998).

ECG ve PPG sinyallerinden:

- PTT:

Nabız dalgasının kalpten periferik bir damara ulaşması için geçen süredir. Fizyolojik olarak, sol ventrikülün kasılmasıyla başlar ve nabız dalgasının periferik arterde algılanmasıyla sonlanır. PTT, arteriyel sertlik ve kan basıncı ile ilişkilidir; arteriyel sertlik arttıkça PTT kısalır, bu da kan basıncının yükselmesiyle doğrudan ilişkilidir. Manşonsuz kan basıncı tahmini algoritmalarında kritik bir özelliktir. PTT, ECG ve PPG sinyallerinden çıkarılabilen bir zamanlama ölçütüdür. PTT değeri nin sinyallerden başlangıç ve bitiş olarak alınan noktalara göre farklılık göstermektedir. Bu çalışmada kullanılmış 2 tane PTT değeri, birinci PTT değeri başlangıç noktası ECG sinyalindeki R tepe noktası iken bitiş noktası PPG sinyalindeki sistolik tepe noktası alınmıştır. İkinci PTT değeri ise başlangıç olarak ECG tepe noktası, bitiş noktası ise atımın başlangıcıdır. Çalışmada kullanılan PTT değeri Şekil 3.8’de gösterilmektedir.



Şekil 3.8. Çalışmada kullanılan PTT değerleri

Kan basıncı değerleri tahmini için kullanılacak özellikleri hesapladıktan sonra girdi matrisi olarak tanımlanmıştır. Girdi matrisi için normalizasyon işlemi gerçekleştirilmiştir.

3.4.3. Normalizasyon

Makine öğrenmesinde normalizasyon, giriş değişkenlerini (X değerleri) belirli bir ölçek veya aralıkta yeniden düzenleme işlemidir. Bu işlem, özellikle farklı birimlerde veya ölçeklerde olan özelliklerin aynı ölçekle çalışmasını sağlar ve modelin performansını artırabilir.

Normalizasyon yapmanın önemli avantajları:

Model Kararlılığı: Özellikle gradyan bazlı algoritmalarda (ör. lojistik regresyon, yapay sinir ağları), büyük ölçekli özellikler modelin ağırlıklarını dengesiz şekilde etkileyebilir.

Hızlı ve Doğru Optimizasyon: Özelliklerin aynı aralıkta olması, optimizasyon algoritmalarının daha hızlı ve doğru bir şekilde çalışmasını sağlar. Optimizasyon işlemini tamamlanmasıyla birlikte x olarak isimlendirdiğimiz girdi matrisini oluşturulmuştur. Yolarak isimlendirdiğimiz çıktı matrisi, modelin tahmin etmeye çalıştığı bağımlı değişkenleri temsil etmektedir. Bu çalışmada, y, kan basıncı değerlerini (sistolik kan basıncı SKB ve diyastolik kan basıncı DKB) içermektedir. Y matrisi için SKB ve DKB için kod ayrı ayrı çalıştırılmıştır.

Bu çalışmada kullanılan makine öğrenmesi modelleri eğitmek ve test etmek için girişte belirlendiği gibi hold-out yöntemi kullanılmıştır. Geliştirilen sistem sporculara yönelik olduğu için eğitim süresi kısa tahmin süresi uzun tutmaya çalışılmıştır. Böylelikle sporcular oyundan önce dinlenirken eğitim verisi toplanabilmektedir. Toplanan eğitim verisi kullanarak model

oluřturulmaktadır. Oluřturulan modelle yeni llen girdiler iin basın deęerlerini tahmini yapılmaktadır






4. BULGULAR VE TARTIŞMA

Bu çalışmada sistemin doğru çalışabilirliğinin anlaşılması için üç tane test gerçekleştirilmiştir. Her test için denetimli makine öğrenmesinden tüm regresyon modelleri denenmiş ve başarısına bakılmıştır.


4.1. Hazır veri seti kullanarak kan basıncı tahmini:

Bu çalışmada, UC Irvine Machine Learning (UCI, 2025). Repository açık erişim veri setlerinden yararlanmıştır. PhysioNet veri tabanından elde edilen ve ön işleme adımları uygulanarak doğrulanmış bir veri seti kullanılmıştır. Veri seti, elektrokardiyografi (ECG), fotopletizmografi (PPG) ve arteriyel kan basıncı (AKB) sinyallerini 100 Hz örnekleme frekansı ile içermektedir. Bu sinyaller, kan basıncı tahmini algoritmalarının geliştirilmesi amacıyla temiz ve geçerli veriler sağlayacak şekilde hazırlanmıştır. Veri seti, başlangıçta physionet.org platformundan alınan ham sinyallerden oluşmaktadır. Daha sonra bu sinyallere, hatalı veya eksik verileri temizlemek ve geçerliliğini sağlamak amacıyla ön işleme adımları uygulanmıştır. Bu süreçteki temel hedef, manşonsuz kan basıncı tahmini algoritmalarını tasarlamak için yüksek kaliteli bir veri kümesi oluşturmaktır. Bu veri setindeki verilerle kan basıncı tahmini için eğitim seti için 15 dakikalık, ECG ve PPG sinyalinden veriler alınmıştır. Alınan verilerle makine öğrenmesi modeli eğitilmiştir. Eğitilmiş modelle aynı veri setinden alınmış 60 dakikalık ECG ve PPG sinyal parçalarıyla kod test edilmiştir. Çıktı matrisi için bahsedildiği gibi kullanılan veri seti AKB sinyali içermektedir. Bu sinyal yardımıyla her atım için sistolik ve diyastolik kan basınç değerlerine bulunabilir ve bu değerlerle çıktı matrisleri oluşturulabilmektedir.

ECG ve PPG sinyalleri için materyal ve metot kısmında bahsedilen filtreleme işlemi uygulanmıştır. AKB sinyali için ise SKB ve DKB değerleri her atım için hesaplanıp çıktı matrisine eklenmiştir. ECG ve PPG sinyallerinin ham ve filtrelenmiş halleri sırayla Şekil 4.1. ve Şekil 4.2.'de gösterilmiştir.



Şekil 4.1. Hazır veri setinden alınan ECG sinyal filtreleme



Şekil 4.2. Hazır veri setinden alınan PPG sinyal filtreleme

Filtre işlemi tamamladıktan sonra makine öğrenmesi modeli tasarlarırken kullanılması planlanan özellikleri hesaplamak için gerekli formülleri uygulanmış ve girdi matrisine aktarılmıştır. Girdi matrisine uygulanan normalizasyon işlemi sonucunda değerleri 0 ile 1 arasında bir girdi matrisi oluşturulmaktadır. Çıktı matrisi için AKB sinyalinden DKB ve SKB değerleri elde edilmiştir. Zaman birimiyle 75'er dk'dan oluşan girdi ve çıktı matrisleri eğitim ve test matrisi olarak iki matrise ayırdıktan sonra regresyon modeli denenmiş bu çalışmada kullanılan regresyon modellerinin hiperparametreleri Çizelge4.1'de gösterilmiştir.

Çizelge 4.1. Çalışmada kullanılan regresyon modellerinin hiperparametrelerinin tablosu

Ridge Regression	alpha=1.0
Elastic Net Regression	alpha=0.1, l1_ratio=0.7
Random Forest	n_estimators=100, random_state=42
Decision Tree	random_state=42
Gradient Boosting	n_estimators=100, random_state=42
KNeighbors Regressor	n_neighbors=5
MLP Regressor 1	hidden_layer_sizes=(100, 50), max_iter=500
XGB Regressor	n_estimators=100, random_state=42
AdaBoost Regressor	n_estimators=100, random_state=42
Bagging Regressor	n_estimators=100
SVR	kernel='rbf'
Lasso Regresyon	alpha=0.1

Değerlendirmek amacıyla tek tek MAE değerlerine bakılmıştır. Eldi edilen sonuçlar Çizelge 4.2'de gösterilmiştir.

Çizelge 4.2. Çalışmada kullanılan makine öğrenmesi modelleri değerlendirme tablosu

Makine öğrenmesi modeli	DKB MAE+STD	SKB MAE+STD
Linear Regression	3.6+1.9	13+5
Ridge Regression	3.4+1.5	11.8+2.9
Elastic Net Regression	2.5+0.8	8.4+3.2
Random Forest	3.3+1.4	12.5+5
Decision Tree	3.1+1.1	11.3+5.5
Gradient Boosting	3.2+1.3	12+5
KNeighbors Regressor	3+1.1	10.1+4
MLP Regressor 1	4.1+3	12.6+5.1
XGB Regressor	3.3+1.3	10.7+5.4
AdaBoost Regressor	3+1.2	9.1+4.3
Bagging Regressor	4.2+2.8	19.5+6
Gaussian Process	4.1+1.6	9.3+3
Bayesian Ridge	3.7+2.5	10.3+5
SVR	3.1+1.4	9+2.6
Lasso Regresyon	2.3+0.7	5+1.3

Çizelge 4.1'e göre, uygulanan makine öğrenmesi modelleri arasında en başarılı sonuçları LASSO Regresyon modeli vermiştir. Bu model, özellikle sistolik ve diyastolik kan basıncı tahminlerinde en düşük hata oranlarını sağlamıştır. Bu çalışmada elde edilen sonuçların, literatürde yer alan benzer çalışmalarla karşılaştırılması ise Çizelge 4.2'de sunulmuştur.

Çizelge 4.3. Bu çalışmada elde edilen sonuçların, literatürde yer alan benzer çalışmalarla karşılaştırılma tablosu

Çalışma	Kullanılan Performans Metrikleri	SKB (mmHg)	DKB (mmHg)
Chen et al. (2019)	MAD+STD	3.27 ± 5.52	1.16 ± 1.97
Kachuee et al. (2019)	MAE+STD	12.38 ± 16.17	6.34 ± 8.45
Sun et al. (2016)	MD+STD	0.43+13.52	-
Shaoxiong Sun et al. (2023)	MD+SD	0.08 ± 7.97	-
Wong et al. (2023)	MAE	6.97	-
Choi et al. (2023)	MAE+SD	2.72 ± 3.42	2.29 ± 3.53
gerçekleştirilen Çalışma	MAE+STD	5.00 ± 1.30	2.30 ± 0.70

Bu çalışmanın diğer literatür çalışmalarından temel farkı, gerçek zamanlı sistem tasarımına uygun, kalibrasyon gerektirmeyen bir model öneriyor olmasıdır. Literatürdeki birçok çalışma genellikle önceden kaydedilmiş verilerle çalışmakta, karmaşık sinyal işleme adımları veya bireye özel kalibrasyon gereksinimi duymaktadır. Ayrıca, elde edilen özelliklerin birçoğu gerçek zamanlı olarak çıkarılması zor parametrelerden oluşmaktadır. Buna karşılık, bu çalışmada kullanılan özellikler basit ve hızlı şekilde çıkarılabilir niteliktedir. Bunun yanı sıra, veri toplama süreci özel olarak tasarlanmış bir donanım aracılığıyla doğrudan gerçekleştirilmiş ve deneklerin egzersiz sırasında ölçüm yapılması sağlanarak sistemin sporculara özel uyarlanabilirliği artırılmıştır. Önerilen model, LASSO regresyon ile 5.00 ± 1.30 mmHg SKB ve 2.30 ± 0.70 mmHg DKB hata oranlarına ulaşarak, özellikle SKB tahmininde oldukça başarılı sonuçlar vermiştir.


Bu çalışmada elde edilen standart sapma değerlerinin (özellikle DKB için 0.70 mmHg gibi düşük bir seviye) literatürdeki birçok çalışmadan daha düşük olması dikkat çekicidir. Bu yönleriyle çalışma, hem teknik hem de uygulama açısından literatürdeki yaklaşımlara göre daha bütüncül ve işlevsel bir çözüm sunmaktadır.

4.2. Geliştirilen Sistemle Dinlenme anında Kan Basıncı Tahmini


Materyal ve metot kısmında tarif edilen sensörleri kullanılmıştır. ECG sinyali ölçmek için M5Stack ECG Module 13.2 ve PPG sinyali için M5Stack Heart Rate Unit kullanılmıştır. Çıktı matrisi için her atım için kan basıncı değerleri gerekmektedir. Bu çalışma yapılırken maliyet açısından uygun ve olabildiğince invaziv olmayan bir şekilde gerçekleştirilmesi hedeflenmiştir. Çıktı matrisi olarak hazır veri seti kullanıldığında AKB sinyalinden her atım için SKB ve DKB değerleri hesaplanıp kullanılmıştır. Geliştirilen sistemle test yapıldığında AKB sinyal verisi doğru yoldan elde edilemediği için 3'er dk arayla dolaylı olarak ölçülüp çıktı sinyaline eklenmiştir. Acura marka standart bir manşonlu ölçüm cihazı ile elde edilmiştir. Bu cihaz, klinik olarak doğrulanmış ve güvenilir bir yöntemle sistolik kan basıncı (SKB) ve diyastolik kan basıncı (DKB) değerlerini ölçmektedir.

Sensörlerden ölçülen sinyaller M5Stack Core2 ile toplandıktan sonra EP-NOW kablosuz iletişim protokolü ile makine öğrenmesi kodunu içeren bilgisayara bağlı olan STAMP-S3 modülüne aktarılmıştır. Toplanan sinyalleri bir dosyaya kaydedilmiştir. Sensörleri vücut üzerinden sinyalleri ölçerken test amacıyla kullanılan kan basıncı değerlerini 3'er dakikalık arala ölçülmektedir.

Sensörlerle ölçülen sinyallerin filtrelenmiş halleri Şekil 4.3 ve Şekil 4.4'te gösterilmiştir.



Şekil 4.3. Sensörlerle ölçülen ECG sinyal filtreleme



Şekil 4.4. Sensörlerle ölçülen PPG sinyal filtreleme

Filtre işlemi tamamladıktan sonra kullanılacak özellikler hesaplanıp girdi matrisi oluşturulmuştur. Çıktı matrisi ise her 3 dk ölçülen DKB ve SKB değerlerinden oluşturulmuştur. En son girdi ve çıktı matrisleri hazır veri setiyle eğitilmiş modelle işlenip tahmini kan basıncı değerleri verilmiştir. Tahmini değerler ile ölçülen değerler arasındaki doğruluğa bakmak için MAE değerine bakılmış ve sistolik KB için 2.8, diyastolik KB için ise 5.2 olarak bulunmuştur.

4.3. Geliştirilen Sistemle Antrenman Yaparken Kan Basıncı Tahmini

Kan basıncı değerlerini tahmin edilmek üzere denek koşu bandı üstünde giderek artan hızla yürüttürülmüştür. Dinlenme durumundayken izlenen adımlara benzer bir şekilde tahmin işlemi gerçekleştirilmiştir. Kan basıncı değerleri dinlenme durumundaki gibi 2 dakikalık arayla manşetli cihazla ölçülmüştür. Ölçüm Şekil 4.5’de gösterilmiştir.



Şekil 4.5. Antrenman sırasında yapılan teste ait görsel

Tahmin edilen deęerlerin doęruluęuna bakmak iin MAE deęerleri incelenmiř ve sistolik KB iin 2., diyastolik KB iin ise 5.1 olarak bulunmuřtur.



5. SONUÇLAR VE ÖNERİLER

Bu çalışmada, sporcuların biyolojik sinyalleri kullanılarak invaziv olmayan, sürekli, rahat ve uygun maliyetli bir kan basıncı ölçüm yöntemi geliştirilmesi amaçlanmıştır. Sporcunun hareket halinde olmasından etkilenmeyen ve sporcuya ek bir yük oluşturmeyen bir sistem tasarlanarak, antrenörlerin sporcunun performansını değerlendirmesi, sağlık durumunu izlemesi ve uygun antrenman programları oluşturmaya yardımcı olacak bir sistem geliştirilmiştir. Çalışmanın temel hedefi, elektrokardiyografi (ECG) ve fotopletismografi (PPG) sinyallerinden tahmin modelleri tasarlayarak sporcuların kan basıncı değerlerinin doğru bir şekilde tahmin edebilmektir. Aşağıda bu çalışmada elde edilen sonuçlar ve gelecekte yapılabilecek çalışmalar için öneriler yer almaktadır.

5.1. Sonuçlar

Bu çalışmada, sporcunun vücudu üzerinden elde edilen ECG ve PPG sinyalleri analiz edilerek, kan basıncı ile doğrudan ilişkili olan PTT, P, R, T dalga genlikleri, PPI, sistolik tepe genliği ve B/A oranı gibi parametreler çıkarılmıştır. Bu özellikler hem dinlenme hem de hareket hâlinde kullanılarak tahmin modellerine giriş değişkeni olarak dahil edilmiştir.

Geliştirilen makine öğrenmesi modelleri, sporcuların sistolik (SKB) ve diyastolik (DKB) kan basıncı değerlerini yüksek doğrulukla tahmin etmiştir. LASSO regresyon algoritması en iyi sonuçları sağlamış ve SKB ile DKB tahminleri için ortalama mutlak hata (MAE) değerleri düşük seviyelerde kalmıştır.

Tasarlanan sistem, klasik manşetli yöntemlerden farklı olarak invaziv olmayan ve sürekli ölçüm yapabilen bir yöntem sunmuştur. Bu sayede, sporcuların hareket halindeyken bile doğru ve güvenilir kan basıncı tahmini yapılabilmesi sağlanmıştır.

Sistem, hafif ve taşınabilir yapısıyla sporcunun performansını olumsuz etkilemeyecek şekilde geliştirilmiştir. Ayrıca, hareket sırasında güvenilir veri sağlayarak sporcuların anlık sağlık durumlarının takibini mümkün kılmıştır.

Geliştirilen tahmin modelleri, farklı sporcular ve farklı durumlar (dinlenme, antrenman gibi) için başarılı tahmin sonuçları üretmiştir. Bu da önerilen yöntemin genelleştirilebilirliğini göstermektedir.

5.2. Öneriler

Modelin daha geniş kapsamlı ve dayanıklı hale gelebilmesi için farklı yaş gruplarından, spor branşlarından ve çeşitli fiziksel özelliklere sahip sporcuların veri setine dahil edilmesi önerilmektedir. Bu çeşitlilik, modelin hem doğruluğunu hem de genelleştirilebilirliğini artıracaktır.

Sporcunun farklı antrenman seviyelerinde (dinlenme, hafif egzersiz, yoğun antrenman) kan basıncı değişimlerini göz önünde bulundurarak yapılacak analizler, modelin gerçek koşullara

uyumunu artırabilir. Özellikle yüksek performans düzeylerinde veri toplanması, tahmin başarımını daha da geliştirecektir.

Sistemin gerçek zamanlı çalışmasını sağlamak amacıyla daha hızlı ve optimize algoritmalar kullanılabilir. Böylelikle sporcuların anlık kan basıncı değerleri eş zamanlı olarak izlenebilir ve bu durum sistemin uygulama alanlarını genişletebilir.

Sistem, hafif ve giyilebilir bir cihaz ile entegre edilerek saha kullanımına daha uygun hâle getirilebilir. Mobil uygulamalarla desteklenmesi sayesinde antrenörler ve sporcular, anlık veri analizleri yaparak performans değerlendirmelerini eş zamanlı olarak gerçekleştirebilir.

Bunun yanı sıra, yalnızca kan basıncı tahminiyle sınırlı kalmadan, elde edilen verilerin sporcunun sakatlık riski hakkında erken uyarılar verecek şekilde kullanılması da mümkündür. Örneğin, belirli SKB ve DKB düzeylerine dayalı olarak sakatlık riski puanlaması sunan karar destek sistemleri geliştirilebilir.

Son olarak, oksijen satürasyonu, solunum hızı ve kalp hızı değişkenliği (HRV) gibi farklı fizyolojik parametrelerin modele entegre edilmesi, sporcunun genel sağlık durumunun daha bütüncül bir şekilde değerlendirilmesine katkı sağlayacaktır.

KAYNAKLAR

- Aksoy, A., Nalbantoğlu, B. ve Kanan, N. (2003). Arteriyel kan basınç ölçümlerinde iki non-invaziv yöntemin karşılaştırılması. Hacettepe Üniversitesi Hemşirelik Fakültesi Dergisi, (50): 81-93..
- Aktaş, F. ve Baydemir, B., 2024. Spor bilimleri alanında kullanılan güç ve kuvvet testlerinden bazılarının değerlendirilmesi. İçinde O. Mülazımoğlu, T. Yılmaz ve E. A. Uluç (Ed.), Spor Bilimleri Alanında Akademik Araştırma ve Değerlendirmeler IX. Özgür Yayınları, 19-36. <https://doi.org/10.58830/ozgur.pub636.c2748>
- Aladwani, F. ve Elsharkawy, A., 2023. Improved prediction of heavy oil viscosity at various conditions utilizing various supervised machine learning regression. Petroleum Science and Technology, 41(4): 406–424. <https://doi.org/10.1080/10916466.2022.2060254>
- Alexander, B., Cannesson, M. ve Quill, T. J., 2013. Blood pressure monitoring. İçinde J. Ehrenwerth, J. B. Eisenkraft ve J. M. Berry (Ed.), Anesthesia Equipment (2. Baskı), ss. 273–282. W.B. Saunders, Philadelphia. <https://doi.org/10.1016/B978-0-323-11237-6.00012-1>
- Allen, J., 2007. Photoplethysmography and its application in clinical physiological measurement. Physiological Measurement, 28(3): R1.
- Alpu, Ö., Şamkar, H. ve Altan, E., 2010. Sağlam ridge regresyon analizi ve bir uygulama. Dokuz Eylül Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi, 25(2): 137–148.
- Andersen, K. L., 1971. Fundamentals of Exercise Testing. World Health Organization, Geneva, ss:133.
- Ashley, E. A., Myers, J. ve Froelicher, V., 2000. Exercise testing in clinical medicine. The Lancet, 356(9242): 1592–1597. [https://doi.org/10.1016/S0140-6736\(00\)03138-X](https://doi.org/10.1016/S0140-6736(00)03138-X)
- Aytekin, H. T., 2021. Makine öğreniminin araştırmacıların veri analizi bağlamında potansiyel önemi. Ufuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 10(19): 85–106.
- Baharvand, S. ve Ahmari, H., 2024. Application of machine learning approaches in particle tracking model to estimate sediment transport in natural streams. Water Resources Management, 38(8): 2905–2934.
- Barker, A. R. ve Armstrong, N., 2010. Exercise testing elite young athletes. <https://doi.org/10.1159/000320642>
- Bilgin, M. ve Şentürk, İ. F., 2019. Danışmanlı ve yarı danışmanlı öğrenme kullanarak doküman vektörleri tabanlı tweetlerin duygu analizi. Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 21(2): 822–839.
- Bonnafox, P., 1996. Auscultatory and oscillometric methods of ambulatory blood pressure monitoring, advantages and limits: A technical point of view. Blood Pressure Monitoring, 1(3): 181–185.

- Breiman, L., 1996. Bagging Predictors. *Machine Learning*, 24(2), 123–140. DOI: 10.1007/BF00058655.
- Breiman, L., 1996. Bagging predictors. *Machine Learning*, 24(2): 123–140. <https://doi.org/10.1007/BF00058655>
- Breiman, L., 2001. Random Forests. *Machine Learning*, 45(1): 5–32. <https://doi.org/10.1023/A:1010933404324>
- Buchanan, S., Orris, P. ve Karliner, J., 2011. Alternatives to the mercury sphygmomanometer. *Journal of Public Health Policy*, 32(1): 107–120. <https://doi.org/10.1057/jphp.2010.38>
- Büyüküysal, M. C., 2010. Ridge regresyon analizi ve bir uygulama. Yüksek lisans tezi, Bursa Uludağ Üniversitesi, Bursa, 53.
- Chen, S., Ji, Z., Wu, H. ve Xu, Y., 2019. A non-invasive continuous blood pressure estimation approach based on machine learning. *Sensors*, 19(11): 2585.
- Chen, T. ve Guestrin, C., 2016. XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794. ACM, San Francisco, USA. <https://doi.org/10.1145/2939672.2939785>
- Durak, M. H. ve Hark, C., 2024. Metin tabanlı veriler üzerinde makine öğrenmesi yöntemlerine dayalı duygu analizi. *Computer Science*, [cilt/sayı bilgisi eksik]. <https://doi.org/10.53070/bbd.1437223>
- Edwards Lifesciences, 2025. ClearSight System. Erişim adresi: <https://www.edwards.com/healthcare-professionals/products-services/hemodynamic-monitoring/clearsight-system>, Erişim tarihi: 22 Nisan 2025.
- Farhan, K., Naqvi, S. T. S., Rizvi, S. A. H., Zafar, A. ve Rawala, M. S., 2020. Comparison between blood pressure readings using a mercury versus an aneroid sphygmomanometer. *Blood Pressure Monitoring*, 25(1): 34–38.
- Freund, Y. ve Schapire, R. E., 1997. A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of Computer and System Sciences*, 55(1): 119–139.
- Friedman, J. H., 2001. Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29(5): 1189–1232.
- Ghareeb, S., Youssef, G., Ghareeb, H. S., El-Mageed, H. A., Mesalm, M. H., Talaat, R. ve Ibrahim, M. M., 2021. Results of a project to calibrate mercury sphygmomanometer blood pressure-measuring devices in Egypt. *Journal of Human Hypertension*, 35(10): 921–926. <https://doi.org/10.1038/s41371-020-00424-0>
- Gökalp, Ö. M., 2022. Makine öğrenmesi. Gazi Üniversitesi, Gazi Bilişim Enstitüsü, Adli Bilişim Bölümü, Ankara, 14 s.
- Hurwitz, J. ve Kirsch, D., 2018. *Machine Learning for Dummies*. IBM Limited Edition, 75 s. ISBN: 9780429196645–9780429196646.

- Husby, M. P., Soliman, E. Z., Goldberger, J. J., Liu, K., Lloyd-Jones, D., Durazo-Arvizu, R. ve Kramer, H., 2015. The association between the PR interval and left ventricular measurements in the multiethnic study of atherosclerosis. *Cardiology Research and Practice*, 2015: 1–8. <https://doi.org/10.1155/2015/193698>
- James, G., Witten, D., Hastie, T., Tibshirani, R. ve Taylor, J., 2023. Unsupervised learning. İçinde G. James, D. Witten, T. Hastie, R. Tibshirani ve J. Taylor (Ed.), *An Introduction to Statistical Learning*, ss. 503–556. Springer International Publishing, Cham. https://doi.org/10.1007/978-3-031-38747-0_12
- Kachuee, M., Kiani, M. M., Mohammadzade, H. ve Shabany, M., 2015. Cuff-less high-accuracy calibration-free blood pressure estimation using pulse transit time. 2015 IEEE International Symposium on Circuits and Systems (ISCAS), 1006–1009.
- Karaçay, S. N. A., 2022. Kelepçesiz tansiyon aleti analizi ve tasarımı. Yüksek lisans tezi, Fatih Sultan Mehmet Vakıf Üniversitesi, İstanbul,s:110.
- Keller, K., Hartung, K., del Castillo Carillo, L., Treiber, J., Stock, F., Schröder, C. ve Friedmann-Bette, B., 2022. Exercise hypertension in athletes. *Journal of Clinical Medicine*, 11(16): 4870. <https://doi.org/10.3390/jcm11164870>
- Kılıç, S., 2013. Linear regression analysis. *Journal of Mood Disorders*, 3(2): 90. <https://doi.org/10.5455/jmood.20130624120840>
- Kubat, M., 1999. Neural networks: A comprehensive foundation by Simon Haykin, Macmillan, 1994. *The Knowledge Engineering Review*, 13(4): 409–412.
- Liu, Q. ve Wu, Y., 2012. Supervised Learning. *Encyclopedia of Machine Learning*, Springer, Boston, MA. DOI: 10.1007/978-1-4419-1428-6_451.
- Li, Y., Li, F., Li, Y., Cui, X., Li, J., Zhi, H. ve Cui, W., 2020. Effect of cuff positioning on the accuracy of blood pressure measurement with automated electronic blood pressure monitors. *The Journal of Clinical Hypertension*, 22(7): 1163–1172. <https://doi.org/10.1111/jch.13902>
- MacKay, D. J., 1992. Bayesian interpolation. *Neural Computation*, 4(3): 415–447.
- Magnani, J. W., Wang, N., Nelson, K. P., Connelly, S., Deo, R., Rodondi, N. ve Health, Aging and Body Composition Study adına, 2013. Electrocardiographic PR interval and adverse outcomes in older adults: the Health, Aging, and Body Composition Study. *Circulation: Arrhythmia and Electrophysiology*, 6(1): 84–90. <https://doi.org/10.1161/CIRCEP.112.975342>
- Mahesh, B., 2020. Machine learning algorithms—a review. *International Journal of Science and Research (IJSR)*, 9(1): 381–386.
- McDonald, G. C., 2009. Ridge regression. *WIREs Computational Statistics*, 1(1): 93–100. <https://doi.org/10.1002/wics.14>
- McVicker, J. T., 2001. Blood pressure measurement—does anyone do it right?: An assessment of the reliability of equipment in use and the measurement techniques of clinicians. *The Journal*

- of Family Planning and Reproductive Health Care, 27(3): 163–164.
<https://doi.org/10.1783/147118901101195407>
- Medwelt, 2025. Tansiyon Holteri Ürün Sayfası. Erişim adresi: https://www.medwelt.com.tr/tr/urun-detay/tansiyon-holterI_5554, Erişim tarihi: 22 Nisan 2025.
- Meidert, A. S. ve Saugel, B., 2018. Techniques for non-invasive monitoring of arterial blood pressure. *Frontiers in Medicine*, 4: 231. <https://doi.org/10.3389/fmed.2017.00231>
- M5Stack, 2025b. Module13.2 ECG. Erişim adresi: <https://docs.m5stack.com/en/module/ecg>, Erişim tarihi: 22 Nisan 2025.
- M5Stack, 2025c. M5Stack Core2 ESP32 IoT Development Kit V1.1. Erişim adresi: <https://shop.m5stack.com/products/m5stack-core2-esp32-iot-development-kit-v1-1>, Erişim tarihi: 22 Nisan 2025.
- M5Stack, 2025d. Stamp-S3. Erişim adresi: <https://docs.m5stack.com/en/core/StampS3>, Erişim tarihi: 22 Nisan 2025.
- M5Stack, 2025e. Unit Heart. Erişim adresi: <https://docs.m5stack.com/en/unit/heart>, Erişim tarihi: 22 Nisan 2025.
- M5Stack, 2025f. Module13.2 ECG. Erişim adresi: <https://docs.m5stack.com/en/module/ecg>, Erişim tarihi: 22 Nisan 2025.
- M5Stack, 2025. Module13.2 ECG. Erişim adresi: <https://docs.m5stack.com/en/module/ecg>, Erişim tarihi: 22 Nisan 2025.
- Nelson, N. ve Asplund, C. A., 2016. Exercise testing: who, when, and why? *PM&R*, 8(3, Supplement): S16–S23. <https://doi.org/10.1016/j.pmrj.2015.10.019>
- Noonan, V. ve Dean, E., 2000. Submaximal exercise testing: clinical application and interpretation. *Physical Therapy*, 80(8): 782–807. <https://doi.org/10.1093/ptj/80.8.782>
- Ortiz-Bejar, J., Graff, M., Tellez, E. S., Ortiz-Bejar, J. ve Jacobo, J. C., 2018. K-nearest neighbor regressors optimized by using random search. 2018 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC), 1–5. IEEE.
- Pathak, S., Mishra, I. ve Swetapadma, A., 2018. An assessment of decision tree based classification and regression algorithms. 2018 3rd International Conference on Inventive Computation Technologies (ICICT), 92–95. IEEE.
- Peng, R.-C., Li, Y. ve Yan, W.-R., 2021. A correlation study of beat-to-beat RR intervals and pulse arrival time under natural state and cold stimulation. *Scientific Reports*, 11(1): 11215.
- Ranstam, J. ve Cook, J. A., 2018. LASSO regression. *Journal of British Surgery*, 105(10): 1348–1348.
- Rasmussen, C. E., 2004. Gaussian processes in machine learning. İçinde O. Bousquet, U. Von Luxburg ve G. Rätsch (Ed.), *Advanced Lectures on Machine Learning*, ss. 63–71. Springer Berlin Heidelberg, Berlin, Heidelberg. https://doi.org/10.1007/978-3-540-28650-9_4

- Reed, J. L., Cotie, L. M., Cole, C. A., Harris, J., Moran, B., Scott, K. ve Pipe, A. L., 2020. Submaximal exercise testing in cardiovascular rehabilitation settings (BEST Study). *Frontiers in Physiology*, 10: 1517. <https://doi.org/10.3389/fphys.2019.01517>
- Respirox, 2025a. AXD-808 Türkçe Konuşan Koldan Tansiyon Aleti. Erişim adresi: <https://www.respirox.com.tr/urun/axd-808-turkce-konusan-koldan-tansiyon-aleti/>, Erişim tarihi: 22 Nisan 2025.
- Respirox, 2025b. AXD-808 Türkçe Konuşan Koldan Tansiyon Aleti. Erişim adresi: <https://www.respirox.com.tr/urun/axd-808-turkce-konusan-koldan-tansiyon-aleti/>, Erişim tarihi: 22 Nisan 2025.
- Sartor, F., Vernillo, G., de Morree, H. M., Bonomi, A. G., La Torre, A., Kubis, H.-P. ve Veicsteinas, A., 2013. Estimation of maximal oxygen uptake via submaximal exercise testing in sports, clinical, and home settings. *Sports Medicine*, 43(9): 865–873. <https://doi.org/10.1007/s40279-013-0068-3>
- Scikit-learn, 2025b. Gradient Boosting Regression Example. Erişim adresi: https://scikit-learn.org/stable/auto_examples/ensemble/plot_gradient_boosting_regression.html, Erişim tarihi: 22 Nisan 2025.
- Scikit-learn, 2025c. MLPRegressor — scikit-learn 1.6.1 documentation. Erişim adresi: https://scikit-learn.org/stable/modules/generated/sklearn.neural_network.MLPRegressor.html, Erişim tarihi: 22 Nisan 2025.
- Scikit-learn, 2025. Cross-validation: evaluating estimator performance. Erişim adresi: https://scikit-learn.org/stable/modules/cross_validation.html, Erişim tarihi: 22 Nisan 2025.
- Scikit-learn, 2025d. Decision Tree Regression Example. Erişim adresi: https://scikit-learn.org/stable/auto_examples/tree/plot_tree_regression.html, Erişim tarihi: 22 Nisan 2025.
- Sharman, J. E., Tan, I., Stergiou, G. S., Lombardi, C., Saladini, F., Butlin, M. ve Parati, G., 2023. Automated ‘oscillometric’ blood pressure measuring devices: how they work and what they measure. *Journal of Human Hypertension*, 37(2): 93–100. <https://doi.org/10.1038/s41371-022-00693-x>
- Shushan, T., Lovell, R., Buchheit, M., Scott, T. J., Barrett, S., Norris, D. ve McLaren, S. J., 2023. Submaximal fitness test in team sports: a systematic review and meta-analysis of exercise heart rate measurement properties. *Sports Medicine - Open*, 9(1): 21. <https://doi.org/10.1186/s40798-023-00564-w>
- Sun, Sb., Bresch, E., Muehlsteff, J., Schmitt, L., Long, X., Bezemer, R. ve Aarts, R. M., 2023. Systolic blood pressure estimation using ECG and PPG in patients undergoing surgery. *Biomedical Signal Processing and Control*, 79: 104040.
- Sun, S., Bezemer, R., Long, X., Muehlsteff, J. ve Aarts, R. M., 2016. Systolic blood pressure estimation using PPG and ECG during physical exercise. *Physiological Measurement*, 37(12): 2154.

- Şahinler, S., 2000. En küçük kareler yöntemi ile doğrusal regresyon modeli oluşturma'nın temel prensipleri. *Mustafa Kemal Üniversitesi Ziraat Fakültesi Dergisi*, 5(1-2): 57-73.
- Takazawa, K., Tanaka, N., Fujita, M., Matsuoka, O., Saiki, T., Aikawa, M. ve Ibukiyama, C., 1998. Assessment of vasoactive agents and vascular aging by the second derivative of photoplethysmogram waveform. *Hypertension*, 32(2): 365-370. <https://doi.org/10.1161/01.HYP.32.2.365>
- Teng, X. F. ve Zhang, Y. T., 2003. Continuous and noninvasive estimation of arterial blood pressure using a photoplethysmographic approach. *Proceedings of the 25th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 4: 3153-3156. IEEE.
- Tranmer, M. ve Elliot, M., 2008. Multiple linear regression. *The Cathie Marsh Centre for Census and Survey Research (CCSR)*, 5(5): 1-5.
- Türk Kardiyoloji Derneği, 2023. Erişkinlerde Hipertansiyon Tanı ve Tedavi Kılavuzu (2023). https://tkd.org.tr/kilavuz/k03/3_18530.htm?wbnum=1103 [Son erişim tarihi: 21.04.2025].
- UCI, 2025b. Cuff-Less Blood Pressure Estimation Data Set. UCI Machine Learning Repository. Erişim adresi: <https://archive.ics.uci.edu/dataset/340/cuff+less+blood+pressure+estimation>, Erişim tarihi: 22 Nisan 2025.
- UCI, 2025. Cuff-Less Blood Pressure Estimation Data Set. UCI Machine Learning Repository. Erişim adresi: <https://archive.ics.uci.edu/dataset/340/cuff+less+blood+pressure+estimation>, Erişim tarihi: 22 Nisan 2025.
- Valler-Jones, T. ve Wedgbury, K., 2005. Measuring blood pressure using the mercury sphygmomanometer. *British Journal of Nursing*, 14(3): 145-150. <https://doi.org/10.12968/bjon.2005.14.3.17519>
- Volis, I. ve Zafrir, B., 2024. Clinical insights into physical activity, fitness, and cardiovascular health. *Journal of Clinical Medicine*, 13(19): 5865. <https://doi.org/10.3390/jcm13195865>
- Vupa, Ö. ve Alma, Ö. G., 2008. Regresyon analizinde kullanılan en küçük kareler ve en küçük medyan kareler yöntemlerinin karşılaştırılması. *Süleyman Demirel University Faculty of Arts and Science Journal of Science*, 3(2): 219-229.
- Quinlan, J. R., 1986. Induction of decision trees. *Machine Learning*, 1(1): 81-106. <https://doi.org/10.1007/BF00116251>
- Wang, R., Jia, W., Mao, Z.-H., Scialabassi, R. J. ve Sun, M., 2014. Cuff-free blood pressure estimation using pulse transit time and heart rate. *2014 12th International Conference on Signal Processing (ICSP)*, 115-118. IEEE.
- Ward, M. ve Langton, J. A., 2007. Blood pressure measurement. *Continuing Education in Anaesthesia Critical Care & Pain*, 7(4): 122-126. <https://doi.org/10.1093/bjaceaccp/mkm022>
- Wiering, M. ve Van Otterlo, M. (Ed.), 2012. Reinforcement Learning: State-of-the-Art. Springer Berlin Heidelberg, Berlin, Heidelberg. <https://doi.org/10.1007/978-3-642-27645-3>

- Williams, B., Poulter, N. R., Brown, M. J., Davis, M., McInnes, G. T., Potter, J. F. ve British Hypertension Society, 2004. Guidelines for management of hypertension: report of the fourth working party of the British Hypertension Society, 2004-BHS IV. *Journal of Human Hypertension*, 18(3): 139–185. <https://doi.org/10.1038/sj.jhh.1001683>
- Wong, Mb. K. F., Hei, H., Lim, S. Z. ve Ng, E. Y. K., 2023. Applied machine learning for blood pressure estimation using a small, real-world electrocardiogram and photoplethysmogram dataset. *Mathematical Biosciences and Engineering*,
- Wong, M. K. F., Hei, H., Lim, S. Z. ve Ng, E. Y. K., 2023. Applied machine learning for blood pressure estimation using a small, real-world electrocardiogram and photoplethysmogram dataset. *Mathematical Biosciences and Engineering*, 20(1), ss.975–997. DOI: 10.3934/mbe.2023045.
- Zhang, R., Iwasaki, K., Zuckerman, J. H., Behbehani, K., Crandall, C. G. ve Levine, B. D., 2002. Mechanism of blood pressure and R-R variability: insights from ganglion blockade in humans. *The Journal of Physiology*, 543(1): 337–348. <https://doi.org/10.1113/jphysiol.2001.013398>



ÖZGEÇMİŞ

Emine Nur TALİB. 2016 yılında Mersin geçici Eğitim Merkezinde Lisesi'ni tamamladıktan sonra 2017 yılında Çukurova Üniversitesi Mühendislik Fakültesi Biyomedikal Mühendisliği Lisans eğitimini almaya hak kazandı. 4 yıl Lisans eğitimi aldıktan sonra 2021 yılında 3.16 ortalama ile mezun oldu. Mezun olduktan bir dönem sonra Çukurova Üniversitesi Biyomedikal Mühendisliği Anabilim dalı alanında Yüksek Lisans eğitimine başladı.

