



İŞE BAĞLI DİNLENME SÜRELERİNİN MAKİNE ÖĞRENMESİ İLE TAHMİN EDİLMESİ

Melis TÜRKSEVER DAYAL¹, Emin KAHYA^{2*}, N. Fırat ÖZKAN³

¹Coşkunöz Kalıp Makina A.Ş., Fethiye OSB Mh. Sarı Cd No: 7 16140, BURSA

ORCID No : <http://orcid.org/0000-0001-9859-0173>

²Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Endüstri Mühendisliği Bölümü, ESKİŞEHİR,

ORCID No : <http://orcid.org/0000-0001-9763-2714>

³Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Endüstri Mühendisliği Bölümü, ESKİŞEHİR

ORCID No : <http://orcid.org/0000-0003-4464-7052>

Anahtar Kelimeler	Öz
Mola Süresi, Fizyolojik Ölçüm Yöntemleri, Ergonomik Risk Değerlendirme, Enerji tüketimi, Akıllı saat, Makine öğrenmesi	<i>Çalışanların mola sürelerinin tahminlenmesi, iş gücü verimliliğinin artırılması ve verimli personel yönetiminin gerçekleştirilebilmesi için önemli bir konudur. Bu sürelerin değerlendirilmesi çalışma ortamındaki ve çalışandaki dinamiklere bağlı olarak değişkenlik göstermektedir. Ancak genel olarak çalışanların günlük mola süreleri işveren ve iş kanununu belirlediği çerçevede içerisinde olmaktadır. Bu çalışmada, çalışanların fizyolojik ölçümleri, algıladıkları subjektif efor ve ergonomik risk değerlendirme skorları dikkate alınarak, makine öğrenmesi modelleri aracılığıyla mevcut mola sürelerinin yeterliliğinin tespiti ve gerekli olan mola sürelerinin tahminlenmesi amaçlanmıştır. Bu kapsamda farklı zorluk düzeyine sahip üretim bölümlerindeki işleri gerçekleştiren 110 çalışandan; 30 dakikalık çalışma süresince akıllı saat ve akıllı saate ait uygulamalar kullanılarak, KAF (Kandaki Atış Frekansı) ve enerji tüketim (Kcal) değerleri ile pulsmetre aracılığı ile kandaki oksijen düzeyi (SpO₂) değerleri alınmıştır.</i>

*Sorumlu yazar; e-posta : ekahya@ogu.edu.tr

Çalışanların, ergonomik açıdan karşılaştıkları fiziksel iş yüklerini tespit etmek amacıyla, ergonomik risk değerlendirme yöntemlerinden REBA yöntemi ile ölçümler gerçekleştirilmiştir. Çalışanların yaptıkları işte algıladıkları subjektif eforu ölçmek için ise Revize Borg Skalası ile zorlanma düzeyleri alınmıştır. Çalışma anında alınan bu veriler, kişinin mesai içerisinde yaptığı iş süresince harcadığı eforu ve zorlanma derecesine dair bilgileri göstermektedir. Mola süresinin hesaplanabilmesi için çalışanların dinlenme anında harcadıkları enerji (Kcal) ve KAF değerleri de ölçülerek kaydedilmiştir. 110 farklı iş ve çalışandan alınan veriler ışığında oluşturulan farklı makine öğrenmesi modellerine göre hafif – orta – ağır iş gruplarında yapılması gereken yeni mola süreleri sırasıyla; 21,42 dk, 21,52 dk ve 22,87 dk olarak tespit edilerek; mevcut 15 dakikalık mola süresinin çalışma sonuçlarına göre yeniden düzenlenmesi önerilmiştir.

PREDICTION OF WORK-RELATED BREAK DURATIONS USING MACHINE LEARNING

Keywords	Abstract
Break Durations, Physiological Measurement Methods, Ergonomic Risk Assessment, Energy Consumption, Smart watch, Machine learning	<i>Estimating employees' break times is crucial for increasing workforce productivity and achieving efficient personnel management. The evaluation of these periods varies depending on the dynamics of the work environment and the employees. However, generally, employees' daily break times fall within the framework determined by the employer and labor laws. In this study, machine learning models are employed to determine the adequacy of existing break times and predict the necessary break times by considering employees' physiological measurements, perceived subjective effort, and ergonomic risk assessment scores. In this context, data were collected from 110 employees performing tasks in production departments with different levels of difficulty. During a 30-minute working period, values of Heart Rate (HR) and energy consumption (Kcal) were obtained using a smartwatch and its application, along with blood oxygen level (SpO₂) values via a pulse oximeter. These data were included in the dataset as employees' physiological evaluations during work. To identify the physical workload from an ergonomic perspective, measurements were conducted using the Rapid Entire Body Assessment (REBA) method. Additionally, perceived subjective effort levels were measured using the Modified Borg Scale. These data collected during work reflect the effort and stress levels expended by the individual during working hours. However, to calculate</i>

break times, basal metabolism data during rest periods are also necessary. Therefore, energy expenditure (Kcal) and HR values during rest periods were measured and recorded. Based on the data obtained from 110 different tasks and employees, new break times for light, moderate, and heavy work groups were determined using various machine learning models as 21.42 mins, 21.52 mins, and 22.87 mins, respectively. It is recommended to reconsider the currently implemented 15-minute break time based on the results of this study.

Araştırma Makalesi	Research Article
Başvuru Tarihi : 03.07.2025	Submission Date : 03.07.2025
Kabul Tarihi : 14.10.2025	Accepted Date : 14.10.2025

1. Giriş

Birçok ülkede, çalışanlara günlük çalışma süresi içinde belirli bir süre çalışma molası verilmesini zorunlu kılan yasalar mevcuttur. Ülkemizdeki işyerleri, 4857 Sayılı İş Kanunu'na uygun olarak 4 saatten fazla ve 7.5 saate kadar çalışma süreli işyerlerinde 30 dakika mola uygulamaktadırlar. Ancak çalışanların mola sürelerinin belirlenmesinde iş verimliliği ve çalışan memnuniyeti de dikkate alınmalıdır. İşyerlerinde belirlenen mola süreleri, şirket kültürüne ve yapılan işin zorluk düzeyine bağlı olarak arttırılabilmektedir. İşyeri yönetimi, çalışma ortamı ihtiyaçları ve çalışanların talepleri doğrultusunda mola sürelerini planlayabilir. Mola süresinin belirlenmesinde; çalışma koşulları, işin oluşturduğu yük ve çalışanların bireysel ihtiyaçları gibi faktörler göz önünde bulundurulmalıdır. Bazı iş yerleri esnek mola politikaları uygulayarak çalışanların verimliliğini arttırmayı hedefleyebilir. Birçok işyeri ise belirli bir çalışma süresinden sonra belirlenen süre kadar mola verilmesini uygun görmektedir.

Çalışanların mola sürelerinin belirlenmesi, iş gücü verimliliğinin arttırılması ve verimli personel yönetiminin gerçekleştirilmesi için önemlidir. Bu sürelerin belirlenmesinde çalışma ortamı şartları (sıcaklık, nem vb.), iş yoğunluğu, fiziksel ve zihinsel zorlanmalar, işin doğası ve çalışanların kişisel ihtiyaçları da etkili olmaktadır. İnsan biyolojik bir olgu olduğundan metabolik farklılıkları da göz ardı edilmemelidir. Aynı işi yapan kişilerin mesai sürecinde harcadıkları enerji ve benzeri özellikler de farklılık göstermektedir. Çalışan verimliliği açısından her işin getirdiği yorgunluğu giderecek kadar dinlenme süresinin tanınması kritik öneme sahiptir (Adem ve Dağdeviren, 2021).

Atölye tipi üretim, bir işletme veya atölyede ürünlerin imalatının yapıldığı bir üretim sistemidir. Bu sistemde, ürünler genellikle bir grup işçi veya uzman tarafından el işçiliği ile üretilir. Atölye tipi üretim genellikle daha küçük ölçekli işletmelerde tercih edilir. Bu üretim tipi, özellikle özelleştirilmiş ürünlerin veya düşük hacimli üretim gereksinimlerinin olduğu durumlarda tercih edilir. Bu sistem, müşteri memnuniyetini artırmak ve özel taleplere hızlı yanıt vermek için

idealdir. Bu tip üretim yapan işletmelerde tüm çalışanlar için belirli bir mola süresi düzenine uyum sağlanması beklenmektedir. Ancak emek yoğun yapılan birçok işin barındırdığı bu işletmelerde tüm çalışanların yorulma ve zorlanma düzeyleri, iş tanımlarına bağlı olarak birbirinden farklılıklar göstermektedir. Bu nedenle, bu çalışmada, otomobil parçaları için kalıp yapım sektöründe faaliyet gösteren ve atölye tipi üretim yapan bir işletmede yer alan işler için hem ergonomik risk ve harcanan eforun subjektif değerlendirmesi hem de fizyolojik yöntemler ile en uygun mola süresinin tahmini amaçlanmıştır.

Kalıp yapım süreci el emeğinin yoğun olduğu, seri üretime kıyasla otomasyon sistemlerinin çok kısıtlı kullanıldığı bir süreçtir. Kalıp yapım atölyeleri atölye tipi üretim sistemlerinin başında gelmektedir. Modern endüstriyel sistemlerde, manuel montaj, birkaç faktör nedeniyle üretimin en önemli aşamalarından biridir: daha yüksek katma değerli görevlerden oluşur, nihai pazara sıkı bir şekilde bağlıdır ve özellikle just-in-time bağlamında yüksek düzeyde esneklik ve nihai ürün kalitesi gerektirir (Dolgui ve Proth, 2010). Böyle atölyelerde tekrarlayan hareketler, yüksek düzeyde fiziksel stres ve zorlayıcı duruşlar mevcuttur. Yüksek fiziksel zorlanmanın sonucu olarak, çalışanlarda işle ilgili kas-iskelet sistemi rahatsızlıkları ortaya çıkmaktadır. Bu tür işlerin çoğu makine desteği olmadan yapıldığından çalışanların uygunsuz çalışma duruşları nedeniyle boyun, sırt, bel, kol, bilek, bacak gibi vücut bölgelerinde ağrılar oluşmaktadır. Uygunsuz çalışma nedeniyle oluşan bu rahatsızlıklar çalışanların ergonomik risk seviyesi yüksek ortamlarda çalışmasının bir sonucudur (Yıldız, Akın, Aydın, Gündüz ve Özalp, 2022). Bu zorlanmaların belirlenebilmesi için birçok ergonomik risk değerlendirme yöntemi literatürde mevcuttur. Bu yöntemler çalışma ortamını ve çalışanın süreç içerisindeki vücut duruşlarını değerlendirerek, çalışma koşullarının risk seviyesi hakkında değerlendirme yapılmasını sağlamaktadır.

Bu çalışmada, çalışanların fizyolojik ölçümleri, algıladıkları subjektif efor ve ergonomik risk değerlendirme skorları dikkate alınarak, makine öğrenmesi modelleri aracılığıyla mevcut mola sürelerinin yeterliliğinin tespiti ve gerekli olan mola sürelerinin tahminlenmesi amaçlanmıştır. Bu çalışma kapsamında çalışanların yorgunluk düzeylerinin belirlenmesi için boy, kilo ve cinsiyet bilgileri ile 30 dakikalık çalışma süresi ve 10 dakikalık mola süreleri boyunca Kalp Atış Frekansı (KAF) ve enerji tüketim miktarı (Kcal) değerleri akıllı saat kullanılarak belirlenmiştir. Pulsmetre aracılığı ile kandaki oksijen düzeyi (SpO_2) ölçülmüştür. Çalışanların yaptıkları işte algıladıkları subjektif efor, bireyin kendi deneyimlerine dayanan ve genellikle kişisel olarak farklılık gösteren bir olgudur. Bu subjektif efor, işin fiziksel ve zihinsel talepleriyle bireyin yetenekleri, motivasyonu, deneyimleri ve duygusal durumu arasındaki etkileşim sonucunda şekillenir. Çalışanların yaptıkları işte algıladıkları subjektif eforu ölçmek için ise Revize Borg Skalası ile değerlendirmeleri alınmıştır. Bu veriler kullanılarak, farklı makine öğrenmesi modelleri kurgulanarak çalışanların yaptıkları işlere göre (hafif – orta – ağır) uygun mola sürelerinin tahmin edilmesi hedeflenmiştir.

2. Bilimsel Yazın Taraması

Literatür taraması çalışmaları:

- a) Ergonomik risk değerlendirme (ERD) yöntemleri ve Borg yöntemi ile yapılan çalışmalar
- b) Harcanan enerjinin ölçümüne yönelik akıllı saatler ile yapılan çalışmalar
- c) Makine öğrenmesi modelleri ile çalışanların enerji verimliliğinin ölçümüne yönelik çalışmalar

olmak üzere üç alt başlık içinde incelenmiştir. Aşağıda son yıllarda yapılan bazı önemli çalışmalar açıklanacaktır.

2.1. ERD ve Borg Yöntemleri ile Yapılan Çalışmalar

Ergonomik risk değerlendirme yöntemleri ile yapılan çalışmalar, ergonomik risk skorlarının hesaplanarak farklı iyileştirme önerileri ile risk düzeylerinin azaltılmasını sağlayan çalışmalardır. Ergonomik risk değerlendirme yöntemleriyle ilgili yapılan literatür çalışmaları oldukça çeşitlidir ve bu alanda birçok farklı yaklaşım ve yöntem bulunmaktadır. Bu çalışmalar, işyerlerinde ergonomik riskleri değerlendirmek ve işçi sağlığını korumak için kullanılan çeşitli yöntemleri incelemekte ve bu yöntemlerin etkinliğini değerlendirmektedir. Bu yöntemler, çalışanların maruz kaldığı ergonomik riskleri belirlemek, işyerlerindeki ergonomik faktörleri iyileştirmek ve iş kazalarını ve işe bağlı sağlık sorunlarını azaltmak için kullanılmaktadır.

Bilimsel yazında, ergonomik risk değerlendirme yöntemlerden biri veya birkaçı kullanılarak; metal, otomotiv, tekstil, mobilya, gıda, tarım, inşaat gibi sektörlerde bedensel işlerde çalışan mavi yakalı personelin yaptıkları işlerde risk skorunu tespit edip yüksek riskli işlemler için iyileştirici öneriler sunulmuş çok sayıda çalışma bulunmaktadır. Bu çalışmada REBA yöntemi kullanıldığından, bu yöntem kullanılarak, özellikle metal ve otomotiv sektöründe yapılmış bazı önemli çalışmalar sunulacaktır.

Kahya, Recal, Sevincer, Gündüz ve Özmutlu (2021), otomotiv üretim endüstrisi koltuk montaj hattında çalışanlara verilen dinlenme paylarının etkisini değerlendirmek üzere REBA, MURİ ve NASA-TLX yöntemlerini kullanmışlardır. Fiziksel iş yükü MURİ ve REBA, zihinsel iş yükü ise NASA-TLX kullanılarak değerlendirilmiştir. AHP ile fiziksel ve zihinsel yorgunluğa ilişkin ağırlıklar oluşturulmuş; her istasyon için çalışanlara değişkenlik gösteren dinlenme payları belirlenmiştir. Zihinsel ve fiziksel yorgunluk analizlerini AHP aracılığıyla birleştirerek yorgunluk hesaplamaları yapılmıştır. Birleşik yorgunluk değerine göre işlemler için dinlenme süresi belirlenmiştir.

Kansu, Parlak ve Güneri (2021), kaynak operasyonlarında çalışan 11 işçinin 18 farklı duruşu için ergonomik risk skorlarını REBA yöntemi ile değerlendirerek yüksek skorlara sahip işlerin risk düzeylerini azaltmaya yönelik öneriler sunmuşlardır. Kaynak proseslerinde en çok gövde (sırt) bacaklar ve kol kısımlarında zorlanmaların yaşandığı gözlemlenmiştir. Dohyung (2021), kas-iskelet sistemi yüklerinin değerlendirilmesinde OWAS, RULA ve REBA yöntemlerini kullanmışlardır. Karşılaştırma, tıp doktorları tarafından teşhis edilen 209 üst vücut kas-iskelet sistemi rahatsızlığı vakasına dayanmaktadır. Mert, İde ve Gündüz (2022), otomotiv sektöründe yedek parça imalatı yapılan progradif kalıp hattında çalışanların kas-iskelet sistemi rahatsızlıkları risklerini QEC ve BAUA yöntemleri ile incelemişlerdir. Çalışanların sağlık kuruluşlarına başvuru sebepleri 2012 – 2019 tarih aralığı baz alınarak incelenmiş ve özellikle bel, genel kas ağrısı, baş ve boyun bölgeleri rahatsızlıkları nedeni başvuruların öne çıktığı saptanmıştır.

Kahya, Alpaslan ve Şenyüz (2023), metal parçaların üretimini gerçekleştiren bir işletmenin üretim bölümünde işçilerin yaptıkları işlem ve montaj faaliyetlerin risk düzeylerinin 5 farklı ergonomik risk değerlendirme yöntemi; REBA, NERPA, QEC, OWAS ve MURI ile tespitini amaçlamışlardır. İşletmede, işçilerin yapmış oldukları 20 işlem belirlenmiş, bunlar gözlemlenerek her işlem için vücut bölgeleri ve diğer bileşenlerin risk skorları 5 yöntem için tespit edilmiştir. Her yöntemin maksimum risk skoruna göre işlemlerin risk skorları % birimine dönüştürülerek normalizasyon işlemi yapılmıştır. 5 uzmana AHP yöntemi uygulanarak yöntemlerin ağırlıkları belirlenmiş ve her işlem için bütünlük risk skoru hesaplanmıştır. Jiao ve diğ. (2024), geliştirilmiş derin öğrenme tabanlı hızlı tüm vücut değerlendirme (REBA) yöntemi önermişlerdir. Yöntem, çalışma videolarını girdi olarak alıp 3D poz rekonstrüksiyonu yoluyla ilgili REBA puanını otomatik olarak çıkarmaktadır. Önerilen yöntem, gerçek dünya verileri üzerinde ergonomi uzmanlarının çalışmaları ile karşılaştırılmış ve ortalama %94,7 hassasiyete ulaşmıştır. Yapıcı ve Öztonga (2025), geleneksel REBA'nın dezavantajlarını ortadan kaldırmak için bulanık kümeler yaklaşımını kullanarak Bulanık-REBA (F-REBA) önermişlerdir. Bulanık REBA yönteminin çalışma esnasında oluşan esneme (fleksiyon) ve gerilme (ektansiyon) nedeniyle eklem yerlerinde oluşan açısız değişimlerin risk skorlarına olan etkisinin daha hassas bir şekilde belirlenebileceği tespit etmişlerdir.

Borg yöntemi kullanılarak son yıllarda gerçekleştirilen birkaç önemli çalışmadan biri olarak, Kumar ve diğ. (2023), iki farklı çalışma pozisyonunda üç ergonomik harç küreği sapının kol ve omuz kaslarının aktivasyonu üzerindeki etkisini deneysel ve subjektif analiz yoluyla belirlemeyi amaçlamıştır. Borg'un CR-10 ölçeği subjektif analizi gerçekleştirmek için kullanılarak modeller arasındaki ortalama rahatsızlık belirlenmiştir. Frasier, Bertrand-Charette, Compagnat, Bouyer ve Roy (2024), kaldırma görevleri sırasında omuzda algılanan yorgunluğun değerlendirilmesi için Borg CR10 kullanmışlardır. 70 kişinin katılımı ile; iki yükün üç ritmik kaldırma görevi ile taşınması ele alınmıştır. Borg CR10'un, omuzda algılanan yorgunluğu değerlendirmek için geçerli bir araç

olduğu belirtilmiştir. Simon ve diğ. (2024), fiziksel zorlamanın Borg CR-10 vücut haritası, ergonomik risk skorları ve ayak basıncı üzerindeki etkisini gerçek bir işyeri ortamında değerlendirmeyi amaçlamışlardır. Lindegård, Grimby-Ekman, Wahlström, ve Gustafsson (2024), Biyofeedback eğitimi ve ergonomik bilgi kombinasyonunun, boyun ve üst ekstremitte semptomları olan genç yetişkin bilgisayar kullanıcılarında ağrıyı azaltıp azaltamayacağına ilişkin bir çalışma gerçekleştirmişlerdir. Algılanan çaba derecelendirmeleri, standartlaştırılmış bilgisayar görevinin hemen öncesinde ve sonrasında Borg CR-10 ölçeği kullanılarak 11 farklı vücut bölgesinde yapılmıştır.

2.2. Harcanan Enerjinin Ölçülmesine Yönelik Çalışmalar

Harcanan enerjinin akıllı saatler ile yapılan ölçümüne yönelik, literatürde birçok çalışma bulunmaktadır. İnsanların enerji harcaması, fiziksel aktivite düzeyine, metabolik hızlarına, yaşlarına, cinsiyetlerine ve genetik yapılarına bağlı olarak değişiklik gösterebilir. Bu çalışmalar, akıllı saatlerin fiziksel aktiviteyi ve enerji harcamasını ölçmedeki doğruluğunu, güvenilirliğini ve kullanılabilirliğini değerlendirir. Bunlar, sağlık profesyonellerinin ve araştırmacıların bu tür cihazları kullanarak insanların enerji harcaması ve fiziksel aktivitesini izlemesine ve değerlendirmesine yardımcı olmaktadır.

Gillinov ve diğ. (2017), çeşitli türlerdeki aerobik egzersiz sırasında beş optik temelli kalp atışı monitörünün doğruluğunu değerlendirmeye yönelik çalışma gerçekleştirmişlerdir. Elli sağlıklı yetişkin üzerinden yapılan egzersizlerde her katılımcı, bir elektrokardiyografik göğüs kemer monitörü (Polar H7), kol monitörü (Scosche Rhythm+) ve iki bilek üzerine takılan kalp atış monitörü ile ölçümler alınmışlardır. Yapılan testlerin sonucunda; tüm egzersiz koşullarında, göğüs kemer monitörü (Polar H7), EKG ile en uyumlu değerleri verirken kullanılan diğer cihazların doğrulukları sırasıyla; Apple Watch, TomTom Spark şeklinde olmuştur. Pasadyn ve diğ. (2019), dört saatte altı farklı koşu bandı hızında kalp ritmini gösteren akıllı saatlerin doğruluğunu ölçen bir çalışma gerçekleştirmiştir. 50 sağlıklı sporcu ile yapılan çalışmada; tüm katılımcılardan EKG ve Polar7 görüş kemeri takmaları ve bunlara ek olarak iki farklı bileğe Apple Watch III, Fitbit Iconic, Garmin Vivosmart HR ve Tom Tom Spark 3 saatlerden rastgele takması talep edilmiştir. Polar H7 göğüs kemerinin EKG ile en yüksek uyumu sağladığı görülmüştür.

Chow ve Yang (2020), genç ve yaşlı yetişkinlerde orta düzey egzersiz sırasında gerçek zamanlı kalp atışını izlemek için iki farklı giyilebilir fitness takip cihazının doğruluğunu incelemiştir. Çalışma içeriğinde Polar H7 göğüs kemerli kalp atış monitörü ile Xiaomi Mi Band 2 ve Garmin Vivosmart HR+ fitness takip cihazı kullanılmıştır. Her iki test cihazı da çeşitli istatistiksel testlere dayanarak kabul edilebilir genel doğruluğa sahip kalp atışı sensörleri olarak belirlenmiştir. Çalışma , yaygın olarak kullanılan optik kalp atışı sensörlerinin, kullanıcının yaşına bakılmaksızın genellikle doğru kalp atışı okumaları ürettiğini ortaya

koymaktadır. Bent, Goldstein, Kibbe ve Dunn (2020), akıllı saatler ile alınan verilerin doğruluğunu değerlendirmek üzere yaptıkları çalışmada kalp atışını ölçmek için kullanılan fotopletizmografiyi etkileyen üç faktörü çalışmalarında konu edinmişlerdir. Farklı giyilebilir cihazların dinlenme ve uzun süreli yüksek kalp atış hızında oldukça doğru olduğunu, ancak aktivite değişikliklerine yanıt verme konusunda cihazlar arasında farklılıklar olduğunu tespit etmişlerdir. Jachymek ve diğ. (2021), akıllı saat kullanımının egzersiz sırasında hastaların kalp atışlarını izlemeye yönelik kullanımını değerlendirmiştir. İki farklı model üzerinden, 30 kişi ile gerçekleştirilen çalışmada Fitbit Charge 4 ve Xaomi Mi Band 5 modellerini kullanmıştır. Koşu bandında gerçekleştirdikleri stres testlerinde, her iki cihazın hassasiyet ve doğruluğunun değişkenlik gösterdiğini tespit etmişlerdir.

Kul, Atıcı Uslu ve Gündüz (2022), farklı personelden elde edilen doğruluk oranlarını düşüren etmenler ile çalışanların fiziksel, fizyolojik ve algıladıkları bilişsel iş yükleri ile ilişkisini incelenmişlerdir. Personelin bilişsel iş yükü NASA-TLX metodu ile, fiziksel iş yükü ise akıllı bileklik ile nabız ve adım sayısı ölçümleri ve REBA yöntemi ile değerlendirilmiştir. Yıldız ve diğ. (2022), kauçuk hortum üretimi yapan bir işletmenin lojistik bölümünde malzeme taşıma işleri için metabolik hız ve enerji yükü değerlendirmesi yapmışlardır. Bu çalışmada metabolik hız harcama modeli kullanılmıştır. Manuel malzeme taşıma için geliştirilen model, bir işin basit görevlere bölünebileceği ve basit görevlerin enerji harcamaları ve işin süresinin bilinmesi ile işin ortalama metabolik enerji harcama oranının tahmin edilebileceğini ortaya koymuştur. Perez ve diğ. (2022), Xaomi Mi Band 4 akıllı bilekliğin adım sayısı ve kalp atış hızı bakımından geçerliliğini ve doğruluğunu analiz etmişlerdir. 46 katılımcı ile gerçekleştirilen çalışmada akıllı saatten okunan değerler ile laboratuvar koşullarında bir video kaydıyla karşılaştırılmıştır. Kim, Kim ve Suh (2022), Kardiyopulmoner Egzersiz Testi sırasında ticari akıllı bilekliklerin kalp atışı ölçümlerinin doğruluğu ve geçerliliğini test etmeye yönelik çalışma gerçekleştirmiştir.

Kahya, Özgen ve Jorayeva (2024), metal parçaların üretimini gerçekleştiren bir işletmenin üretim bölümündeki 20 işlem için ergonomik risk skorları ile enerji tüketim miktarı arasındaki korelasyonları araştırmışlardır. Risk skorları REBA, QEC, OWAS ve MURI yöntemleri ile tespit edilmiştir. İşlemleri yapan işçinin işlem boyunca harcadığı enerji miktarının tespiti için HUAWEI Watch Fit model akıllı saat çalışana takılarak, 120 dk boyunca harcadığı toplam enerji miktarı ile ortalama kalp atış frekansı değerleri kaydedilmiştir. İşlemler için toplam enerji miktarları 292 - 532 Kcal aralığında belirlenmiştir.

2.3. Makine Öğrenmesi Modelleri ile Çalışan Verimliliğinin Ölçümüne Yönelik Çalışmalar

Makine öğrenmesi modelleri ile çalışanların enerji verimliliğinin ölçümüne yönelik çalışmalar giderek artmaktadır. Bu modeller, çeşitli sensör verilerini

kullanarak enerji tüketimini tahmin etmek, enerji israfını belirlemek ve enerji verimliliğini artırmak için kullanılabilir. Bu alanda yapılan çalışmalar incelendiğinde genellikle giyilebilir cihazlarda yer alan algoritmaların ne kadar doğru tahminleme yaptığını ölçen makale çalışmaları mevcuttur. Ancak alınan veriler ile makine öğrenmesi modelinin kurgulanmasına yönelik bir çalışma ile karşılaşılmamıştır.

Li ve Zhang (2018), fiziksel aktivite tanıma sistemlerinde enerji harcaması tahmin modellerini incelemişlerdir. Farklı makine öğrenmesi teknikleri ve veri kaynaklarının kullanımını değerlendirerek, bu alandaki mevcut araştırma eğilimlerini analiz etmişlerdir. Li, Wang ve Wang (2018), imalat endüstrisindeki enerji tüketimi tahminlemesi ile bakım ve enerji verimliliği arasındaki ilişkiyi incelemişlerdir. Makine öğrenimi algoritmalarının kullanımını değerlendirerek, üretim tesislerinde enerji verimliliğini artırmak için nasıl uygulanabileceğini araştırmışlardır. Chen ve Wang (2019), giyilebilir sensörler ve makine öğrenmesi yöntemlerinin kullanımını insan enerji harcamasını tahmin etmek için araştırmışlardır. Sensör verilerinin ve makine öğrenmesi algoritmalarının etkinliği üzerinde durarak, bu alandaki gelecek potansiyeli değerlendirmişlerdir.

Alvarez-Garcia, Cvetkovi ve Lustrek (2020), giyilebilir sensörler ve makine öğrenmesi yöntemlerinin kullanımını, insan enerji harcamasını tahmin etmek için araştırmışlardır. Sensör verilerinin ve makine öğrenmesi algoritmalarının etkinliği üzerinde durarak yaptıkları çalışmada, kişilerin enerji harcaması için mevcut derin ve klasik makine öğrenimi tekniklerinin analizini gerçekleştirmişlerdir. Chen, Liu ve Wang (2020), imalat endüstrisinde enerji tüketiminin tahmini ve analizi üzerine derleme çalışması gerçekleştirmişlerdir. Makine öğrenmesi tekniklerinin kullanımını inceleyerek, farklı enerji tüketimi modellerini değerlendirmişler ve işletmedeki enerji verimliliğini artırmak için potansiyel uygulamaları tartışmışlardır. Smith ve Doe (2020), insan enerji harcamasını tahmin etmek için çeşitli makine öğrenmesi yöntemlerini inceleyen bir çalışma gerçekleştirmişlerdir. Yapılan tarama, özellik seçimi, model seçimi ve performans karşılaştırmaları üzerinde durarak mevcut araştırma eğilimlerini analiz etmişlerdir. O'Driscoll ve diğ. (2021), Fitbit Charge 2, ActiGraph GT3-x, SenseWear Armband Mini ve Polar H7 gibi birkaç giyilebilir cihazda enerji harcamasını tahmin etmek için algoritmaların geçerliliğini ve dış örneklem genelleştirilebilirliğini test etmeyi amaçlamışlardır. Wang, Lu ve Zhao (2021), imalat sektöründeki enerji tüketimi tahminleme tekniklerini ele almışlardır. Çalışma makine öğrenmesi algoritmalarının yanı sıra zaman serisi analizi ve veri madenciliği tekniklerini de içermektedir.

Literatür çalışmaları incelendiğinde enerji tüketimi kapsamında yapılan çalışmalarda doğrudan çalışanların enerji tüketimini ve ergonomik risk seviyelerini bütünleştirerek, makine öğrenmesi modelleri ile mola süresi, yorulma süresi ya da mesai süresi gibi tahminlemeler gerçekleştiren bir çalışmaya rastlanmamıştır. Bu çalışmanın mevcut literatüre katkısı çalışanlardan alınan fizyolojik ölçümler ile, çalışma esnasındaki ergonomik risk

skorlarını ve subjektif efor seviyesini de dikkate alarak, makine öğrenmesi modelleri ile mola süresi tahminlemesini amaçlanmıştır.

3. Çalışmada Kullanılan Yöntem Ve Araçlar

3.1 Makine Öğrenmesi


Yapay zekânın bir alt dalı olarak görülen makine öğrenmesi, bilgisayarlara bir problem çözmek için olabilecek her adımı önceden vermek yerine, algoritmalar ile ne yapacaklarını öğrenmelerini sağlamaktır. Bu durum önceden belirlenmiş bir yolu takip eden programlar yerine, dinamik olarak ortaya çıkabilecek bir soruna daha önce tanımlanmış/öğrenilmiş çok fazla sayıda içerikleri kullanarak çözüm bulan algoritmaların geliştirilmesi demektir (Gürsakan, 2017). Makine öğrenme algoritmaları, verileri kullanarak bir desen ya da bir model oluşturup, bunu gelecekte karşılaşılabileceği yeni durumları tahmin etmede kullanan yazılımlardır. Örneğin, geçmiş ya da anlık olarak piyasayı izleyen bir makinenin, gelecek piyasa analizleri yapması bir makine öğrenmesi olarak kabul edilebilir. Yani, makine öğrenmesi, (1) verilerin analizi, (2) model oluşturma ve (3) modeli kullanarak tanıma adımlarının tekrarlı bir şekilde kullanılarak geliştirildiği bir öğrenme-kullanma süreci olarak değerlendirilebilir (Arslan, 2020).

Yapay Zeka (YZ) kurgusunda, bazı görevleri gerçekleştirmek için bir bilgisayar programı atanır ve makinenin, bu görevleri yerine getirirken daha fazla deneyim kazandıkça bu görevlerdeki ölçülebilir performansının gelişip gelişmediğini kendi deneyimlerinden öğrendiği söylenmektedir (Ray, 2019). Ayrıca örneklenmiş verilere dayalı matematiksel modeller oluşturan algoritmalar da sağlar. Bu matematiksel modeller (fonksiyonlar olarak adlandırılır) girdi verilerini istenen çıktılara eşitler. Girdiler, görüntüler ve rastgele bir sayısal veya kategorik veri dizisi olabilir. YZ'nin amacı veri ve algoritmalara dayalı olarak makineleri eğitmektir. İşlenmiş verileri ve bilgileri kullanarak makinelerin nasıl karar vereceğini öğrenir. Dinamik bir yapıya sahiptir ve daha fazla veri ile karşılaştığında kendini değiştirme ve geliştirme yeteneğine sahiptir (Janiesch, Zschech ve Heinrich, 2021).

Makine öğrenmesi yöntemleri denetimli algoritmalar ve denetimsiz algoritmalar olarak iki gruba ayrılmaktadır. Denetimsiz algoritmalar kümeleme çalışmaları gerçekleştirmektedir. Denetimli algoritmalar ise sınıflandırma ve regresyon içerikli algoritmalar olarak kendi içinde iki gruba ayrılmaktadır.

Denetimli öğrenme örnek girdi-çıktı çiftlerine dayanarak bir girdiyi bir çıktıya eşleyen fonksiyonu öğrenmesidir (Cord ve Cunningham, 2008). Veri seti içerisinde etiketli verilerin kullanılarak modelin eğitilmesine denetimli öğrenme adı verilir. Veri seti eğitim verileri ve test verileri olarak iki kategoriye ayrılır. Makine öğrenmesi modeli etiketlenen eğitim verilerinden hareketle test verilerini yorumlar. Bu sayede verilerde doğru sınıflandırma ve tahminleme

yapmaya çalışır. Denetimli öğrenme algoritmalarının iş akışı Şekil 1’de gösterilmektedir.



Şekil 1. Denetimli Öğrenme Algoritmalarının İş Akışı (Chinnamgari, 2019)

Denetimli öğrenme problem türüne göre iki temel alt kategoriye ayrılır (Zhu ve Goldberg, 2009):

- Sınıflandırma (Classification)
- Regresyon (Regression)

Denetimli öğrenmenin denetimsiz öğrenmeden, yarı denetimli öğrenmeden ve pekiştirmeli öğrenmeden temel farkı etiketli veri setini kullanıp doğru şekilde tahminleme ve sınıflandırma yapabilmesidir. Denetimsiz öğrenmede ise etiketsiz veriler kullanılır (Biamonte ve diğ., 2017). Denetimli öğrenme içerisinde karar ağacı, yapay sinir ağları, rastgele orman, doğrusal regresyon, lojistik regresyon ve en yakın komşuluk yöntemleri yaygın olarak kullanılmaktadır. Bu çalışma kapsamında kullanılan modeller ise a) karar ağacı, b) yapay sinir ağlar ve c) regresyon analizi olmuştur.

Karar ağacı sınıflandırma ve regresyon tahminleri için kullanılan denetimli bir makine öğrenmesi algoritmasıdır. Bağımsız değişkenler ile bağımlı değişken arasındaki ilişki bir ağaç yapısı ve onun dallarıyla modellenir. Karar ağaçları hem sayısal hem de kategorik veride çalışır. Karar ağaçları dallanırken kategorik değişkenler için entropi ve gini değerleri sürekli sayısal değişkenler için ise en küçük kareler yöntemidir. Karar ağaçlarının dal sayısı modelin aşırı uyumuna neden olabilir (Altun, 2022). Karar verirken insan yeteneğini başarılı bir şekilde taklit ettiği, anlaşılması kolay olduğu için sınıflandırma ve tahminleme için en güçlü algoritmalarından birisidir. Ağaç yapısına benzer şekilde ağaç benzeri kök düğümle başlayıp ve daha fazla dalda genişlemesi sebebiyle algoritma karar ağacı olarak adlandırılmıştır. Algoritmanın çalışma mantığı ağaç yapısına benzer. Algoritmanın amacı, veri setinin özelliklerinden çıkarılan basit karar kuralları öğrenmek ve bir bağımlı değişkenin değerini tahmin eden bir model

oluşturmaktır. Karar ağaçları hem kategorik hem de sürekli değişkenleri işleyebilir. Bir veri kümesini aşamalı daha küçük alt kümelere ayırırken aynı zamanda ilgili bir karar ağacı aşamalı olarak geliştirilir. Ağaç, bir kök düğümden başka bir ifade ile karar düğümü, iç düğüm ve yaprak düğümden oluşur (Friedl ve Brodley, 1997; Vafeiadis, Diamantaras, Sarigiannidis ve Chatzisavvas, 2015).

Yapay sinir ağları, insan beyninin biyolojik sinir ağları çalışma prensibinin matematiksel olarak modellenmesini hedef alan, algoritmalar ile kodlanmış, önceden öğrenilmiş ya da sınıflandırılmış veri setlerini kullanarak yeni bilgiler oluşturabilen, karar verebilen ve sınıflandıran yazılım uygulamalarıdır (Altun, 2022).

Yapay sinir ağları, insan beyninin işleyişinden esinlenerek tasarlanmış bir makine öğrenimi algoritması olduğundan birbirine bağlı birçok yapay sinir hücresinden oluşan katmanlar halinde düzenlenmiştir. Her bir sinir hücresi, girdi verilerini alır, bu verileri ağırlıklarla çarparak bir aktivasyon fonksiyonuna sokar ve sonuç olarak bir çıkış üretir. Bu ağlar, genellikle bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanı içerir. Eğitim sürecinde, ağırlık parametreleri (ağırlıklar ve biaslar) veri setine göre ayarlanır, böylece istenen çıktıya mümkün olan en yakın sonuç elde edilir. Bu şekilde, yapay sinir ağları geniş bir veri setinde karmaşık ilişkileri ve desenleri öğrenip genelleme yapabilirler, yani eğitim verisindeki örüntüleri tanıyarak yeni verilerde tahminlerde bulunabilirler. Bu nedenle, yapay sinir ağları, sınıflandırma, regresyon, kümeleme ve diğer birçok makine öğrenimi görevinde başarıyla kullanılır.

Regresyon analizi özellik (bağımsız değişken) veya özelliklerle bir bağımlı değişken arasındaki ilişkiyi belirlemek için kullanılır. Regresyon için kıdem-ücret, çalışma süresi-alınan not ve kan değerleri-hastalık durumu gibi örnekler verilebilir. Regresyon analizi gözetimli öğrenme yöntemlerindendir. Doğrusal ve doğrusal olmayan regresyon modelleri bulunmaktadır (Altun, 2022). Bu analiz makine öğrenimi ve istatistiksel analizin önemli bir yöntemidir. Genellikle bir bağımlı değişkenin, bir veya daha fazla bağımsız değişkene nasıl bağlı olduğunu anlamak için kullanılır. Bu analiz, bu ilişkiyi tanımlayan bir model oluşturur ve bu modeli kullanarak bağımlı değişkenin tahminlerini yapar.

3.2. Ergonomik İnceleme Araçları

Mola sürelerinin yeterliliği, işçinin performansı üzerinde etkili olabileceği için oldukça önemlidir. Çalışanların dinlenme süreleri işyerleri tarafından belirlenen zaman aralıklarında gerçekleştirilmektedir. Ancak işletmelerde birçok iş tanımı ve bu işlerin birbirinden farklı zorluk düzeyleri mevcuttur. Farklı zorluk düzeyinde bulunan işler için dinlenme sürelerinin aynı olması çalışanların yeterli dinlenememe, işgücü verimliliğinde düşüş ve buna bağlı iş kazası risklerini de beraberinde getirmektedir.

Çalışanın ergonomik olarak zorlanma düzeyinin tespiti için ergonomik risk değerlendirme yöntemlerinden, yaygın kullanımı nedeniyle, REBA yönteminin kullanımı tercih edilmiştir. REBA yöntemi Hignett ve McAtamney (2000) tarafından, sayısal ve sözel tablolar kullanarak elle yapılan taşıma, kaldırma işlemlerindeki riski hesaplayarak hatalı duruş pozisyonlarına bağlı oluşacak kas-iskelet sistemi hastalıklarının oluşmasını engellemek için tasarlanmıştır (Sağıroğlu, Coşkun ve Erginel, 2015). REBA yönteminde, vücut bölgeleri olarak; gövde, boyun ve bacak, üst kol, alt kol ve bileklerin duruşu analiz edilir, duruş sırasında uygulanan kuvvet (veya taşınan yük), kavrama ve aktivite skoru eklenerek risk skoru elde edilmektedir. Çok fazla vücut bölgeleri için 4 düzeye kadar puanlama özelliği dolayısıyla daha kapsamlı olduğundan, bu çalışmada kullanımı uygun görülmüştür.

Bu çalışma kapsamına da kullanılan bir diğer ergonomik araç ise Revize Borg Skalasıdır. Borg skalası, algılanan zorluk derecesini belirlemede kullanılan yöntemlerden biridir. Bu yöntem egzersize katılım sağlayan kişilerin egzersizden algıladıkları zorluk derecelerini kendilerinin belirlediği bir yöntem olup bu yönüyle sübjektif bir değerlendirme aracıdır (Akgül, Baltacı, Yıldız, Özcan ve Akgül, 2021). Bu ölçek, İsveçli fizyolog Gunnar Borg tarafından 1960'larda geliştirilmiş ve ismini kendisinden almıştır. Sıklıkla efor şiddetini ve istirahat ihtiyacını değerlendirmek amacıyla kullanılan bir ölçektir. Derecelerine göre zorlanma şiddetini tanımlayan on maddeden oluşur (Burdon, Juniper, Killian, Hargreave ve Campbell, 1982; Kara ve Yıldız, 2013). Egzersiz sırasında bireylerin algıladıkları çabaya dayanarak fiziksel aktivitenin yoğunluğu bu ölçekle derecelendirmek mümkündür. Revize Borg Skalası ise sübjektif fiziksel aktivite yoğunluğunun değerlendirilmesinde kullanılan Borg Skalasının güncellenmiş bir versiyonu olarak Gunnar Borg tarafından geliştirilmiştir. Revize Borg Skalası, 0 ile 10 arasında bir değer aralığı kullanır ve her bir değer, bireyin yaptığı fiziksel aktivitenin yoğunluğunu algıladığı dereceyi temsil etmektedir. 0, hiçbir çaba hissetmediği durumu ifade ederken, 10, maksimum çabayı temsil etmektedir. Skalada, 0-3 hafif, 4-6 orta ve 7-10 ağır iş olarak tanımlanmaktadır.

3.3 Fizyolojik Araçlar

Çalışmanın nihai amacına ulaşabilmek için gözlenen işlerin neden olduğu kalp atış frekansı (KAF), kandaki oksijen düzeyindeki (SpO_2) değişimler ile enerji tüketimi (kalori harcaması) da kullanılmıştır. Bu verilerin toplanması ve gerekli hesaplamalarda kullanılması için göğüs sensörlü giyilebilir teknolojilerle yakın sonuçlar verdiği bilinen (Chow ve Yang, 2020) Xiaomi Mi Band 2 akıllı saat ile parmak ucuna takılarak kandaki oksijen miktarını ölçen bir pulse oksimetre kullanılmıştır. Fiziksel efor esnasında yorgunluğun düzeyiyle ilgili gösterge olarak kabul edilebilecek bu fizyolojik verilerin mola sürelerinin daha doğru tahmin edilmesi açısından önemli olduğu düşünülmüştür.

4. Uygulama

Bu çalışmada, atölye tipi üretim yapan ve otomotiv sektöründe faaliyet gösteren bir işletmenin üretim bölümlerindeki işlemler incelenmiştir. Çalışanların fizyolojik verileri, algıladıkları subjektif efor ve ergonomik risk skorları dikkate alınarak, kurgulanan makine öğrenmesi modelleri ile mola sürelerinin tahmin edilmesi amaçlanmıştır.

Çalışma kapsamında öncelikle kullanılacak yöntemler ve veri setini oluşturacak diğer fizyolojik ölçümler belirlenmiştir. Ergonomik risk değerleri REBA yöntemi kullanılarak belirlenmiştir. Çalışanların subjektif fiziksel aktivite yoğunluğunu değerlendirmek için Revize Borg Skalası ile değerlendirmeleri alınmıştır. Fizyolojik ölçümler için akıllı saat kullanılarak çalışanlardan 30 dakikalık çalışma diliminde KAF ve enerji tüketimi miktarları alınmıştır. Oksimetre yardımı ile çalışma sürecinin başlangıcında ve bitişinde kandaki oksijen düzeyi (SpO_2) değerleri kayıt edilmiştir. Bu veriler çalışanın çalışma anındaki fiziksel aktiviteye bağlı yorgunluğunun belirlenmesini sağlamaktadır. Dinlenme süresinde çalışanların KAF ve harcanan kalori değerleri alınarak, kişinin bazal metabolizmasında harcadığı enerji ve kalp atış frekansı elde edilmiştir. Bu veriler, kurgulanan makine öğrenmesi modeli ile işlenerek hafif, orta ve ağır düzeyde yer alan işler için mola süresi tahminlenmesi gerçekleştirilmiştir. Kurulan makine öğrenmesi modelinde, çalışanın çalışma anı vücut parametrelerinin, bazal metabolizma şartlarına ne kadar sürede indirgeneceği tahminlenmiştir. Ek olarak, literatürde yer alan dinlenme süresi formülü (Bridger, 2017) ile alınan veri seti üzerinden her iş için gerekli mola süresi hesaplanmıştır. Hafif- orta – ağır olarak gruplandırılan işler için hem dinlenme süresi formülü hem de makine öğrenmesi modellerinin çıktıları karşılaştırılmıştır.

Çalışma için, ESOGÜ Fen ve Mühendislik Bilimleri İnsan Araştırmaları Etik Kurulu'nun 05.04.2024 tarih ve E-53893652-050.04-2400069265 sayılı kararı ile etik açıdan uygunluğu alınmıştır.

Bu çalışmada araştırma ve yayın etiğine uyulmuştur.

4.1 Verilerin Toplanması

Verilerin toplanmasına öncelikle üretim sahasında yer alan işler tanımlanarak başlanmıştır. Üretim alanında gerçekleştirilen, tüm kalıp yapım süreçlerinde ortak olarak yer alan 110 işlem tespit edilerek her bir iş için farklı birer iş gören çalışmaya dâhil edilmiştir. Çalışanlar ile yapılan bilgilendirme görüşmelerinde katılım için rızaları alınarak gönüllü katılım formu imzalanmıştır. Bu bireylerden alınacak ölçümler genel çalışma verilerinde sapmalar oluşturabileceğinden kalp, tansiyon ve diyabet gibi tanımlı rahatsızlıkları olan çalışanlar çalışma kapsamının dışında tutulmuştur. Çalışmaya katılan katılımcıların demografik özellikleri Tablo 1'de gösterilmiştir.

Tablo 1.

Katılımcıların Demografik Özellikleri

	Katılımcı Sayısı	Boy(cm)			Kilo(kg)			Yaş (yıl)		
		Mak.	Ort.	Min.	Mak.	Ort.	Min.	Mak.	Ort.	Min.
Erkek	106	188	175,73	163	95	76,16	65	53	35,53	22
Kadın	4	168	163,5	160	77	63	55	38	28	24
Toplam	110	188	175,12	160	95	75,5	55	53	35,15	22

Veri setini oluşturan katılımcılar incelendiğinde, kadın çalışanların sayısının tüm veri seti içindeki oranının %3 olduğu göze çarpmaktadır. Bu oran, işletmenin üretim aşamalarında görev alan tüm çalışanların oranıyla uyumludur. Yaş grupları incelendiğinde ise %25,5 oranında 30 yaş altı, %49 oranında 30 ila 40 yaş aralığındaki bireyler ve %25,5 oranında 40 yaş üstü bireylerin yer aldığı görülmektedir.

Çalışanların bireysel farklılıklarının çalışmaya dahil edilebilmesi için boy, kilo, yaş ve cinsiyet verileri Gözlem Kayıt Formu'na gözlemci tarafından kaydedilmiştir. İlgili çalışmaları gerçekleştiren operatörlere ön bilgilendirme yapılarak; işe başlamadan önce pulsmetre ile kandaki oksijen seviyesi ölçülmüştür. Çalışma sürecinde de akıllı saat takmaları talep edilmiştir.

Akıllı saat, çalışma rutininde çalışma başlangıcında ilk 30 dakika boyunca çalışanın bileğinde kalarak KAF ve enerji tüketim miktarı ölçmüştür. Enerji tüketimi miktarlarının kaydedilmesi sürecinde herhangi bir egzersiz programı ya da ölçüm özelliği seçilmemiştir. Egzersiz modu ile çalışıldığı durumda yapılan işin tam tarifine karşılık gelen bir spor türü bulunmaması, buna bağlı olarak da ölçümün saat tarafından durdurulması nedeniyle enerji tüketimi miktarı akıllı saatin takılı kaldığı süre boyunca alınan toplam ölçüm olarak kaydedilmiştir. KAF maksimum, minimum ve ortalama şeklinde kaydedilmiştir. KAF ölçümünde akıllı saatin ayarlar bölümünden dakikada bir ölçüm alınması seçeneği seçilmiştir. Yapılabilecek en sık ölçüm dakikada bir şeklindedir ve sık ölçüm ile doğruluk oranının artırılması öngörülmüştür. Xiaomi Mi-Band 8 akıllı saat ile ölçümler alınmış olup alınan ölçümlere Mi Fitness uygulaması üzerinden ulaşılmıştır. Ölçüm sonuçları akıllı saatin ilgili telefon uygulamasından ölçüm sonrası alınarak gözlem kayıt formuna kaydedilmiştir.

Çalışanlar akıllı saat takılı olarak işlerini gerçekleştirirken REBA yöntemi ile de işlerin risk değerlendirmeleri gerçekleştirilmiştir.

Çalışma anı verilerinin mola süresine dönüştürülebilmesi için kurgulanacak makine öğrenmesi modeline işi gerçekleştiren bireyin dinlenme anı verilerinin de tanıtılması gereklidir. Tek başına çalışma verileri ile mola süresi tahmini

yapılması anlamlı değildir. Bunun yerine işi gerçekleştiren bireyin hem çalışma anı hem mola anı verileri ile model kurgulanmıştır. Bireyin artan KAF'nın, ne kadar sürede normal frekansına döneceği de modele eklenmiştir ki bu ölçüm modele bireylerin fizyolojik farklarının yansıtılmasını sağlamıştır. Bu nedenle aynı çalışanın 30 dakikalık çalışması sonrasında 15 dakika mola vermesi sağlanmıştır. Çalışanların 30 dk çalışma süresi bittiğinde, akıllı saatin ayarlar bölümünden tüm saat verileri sıfırlanmış, çalışma anına ait tüm verilerin silinmesi gerçekleştirilmiştir. Sonrasında mola sürecine geçilerek ölçümlerin tekrar alınması sağlanmıştır.

Mola başlangıcında ve sonunda pulsmetre ile parmağın kandaki oksijen düzeyi ölçülmüştür. Alınan ölçümler gözlem kayıt formuna kaydedilmiştir. Sonrasında Borg Skalası hakkında kısa bir bilgilendirme yapılarak, çalışanların algıladıkları subjektif eforu Borg Skalası ile değerlendirmeleri talep edilmiştir.

REBA, Borg ölçeği, pulsmetre ve akıllı saat aracılığıyla toplanmış verilerin özeti Tablo 2-4'de sunulmuştur.

Tablo 2.

REBA Değerlendirme Sonuçları

Derece	REBA Skoru	Risk Seviyesi	İş Sayısı
0	1	İhmal Edilebilir	0
1	2-3	Düşük	5
2	4-7	Orta	46
3	8-10	Yüksek	49
4	11-15	Çok Yüksek	10
Toplam			110

REBA değerlendirmeleri sonucu risk tablosu incelendiğinde mevcutta yürütülen işlerin %5'inde düşük risk, %41,2'sinin orta düzey risk, %44,5'inin yüksek risk ve %9,3'ünün çok yüksek risk seviyesinde olduğu görülmektedir. REBA risk skorlarına göre incelenen işlerin %53,8'inde pozisyon veya hareket ergonomik açıdan riskli ve iyileştirmeler yapılması gerekli olduğu söylenebilir.

Tablo 3.

Revize Borg Skalası Skorları

Hissedilen Efor	Borg Skoru	İş Sayısı	İş Düzeyi
Yok	0	0	Hafif
Çok hafif	1	1	Hafif
Hafif	2	7	Hafif
Orta	3	16	Hafif
Biraz Ciddi	4	16	Orta
Ciddi	5	26	Orta
5 ile 7 arası	6	11	Orta
Çok ciddi	7	12	Ağır
7 ile 9 arası	8	15	Ağır
Çok çok ciddi	9	5	Ağır
En şiddetli	10	1	Ağır
Toplam		110	

Yapılan değerlendirmenin sonuçları incelendiğinde, gerçekleştirilen işlerin %21,8'i hafif düzeydeki işlerden oluşmaktadır. %48,2'si orta düzeydeki işlerden oluşmakta olup, %30'u ağır düzeydeki işlerdir. İşletmenin üretim atölyesinde yapılan işlerin yaklaşık olarak yarısının orta ağırlıktaki işlerden oluştuğu söylenebilir. Borg skalası, işlerin, hafifi, orta ve ağır olmak üzere 3 ana gruba ayrılmasında kullanılan bir yöntemdir. Skala sübjektif bir ölçüm yöntemi olduğundan kalori harcaması yüksek ya da REBA risk skoru yüksek olan bazı işler için Borg değerlendirmesi şiddeti düşük ya da tam tersi şekilde kalori harcaması düşük olan bazı işler için Borg değerlendirmesi şiddeti yüksek olarak elde edilebilmektedir.

Çalışma anında alınan verilere bakıldığında işlerin ağırlık düzeylerine göre KAF ölçümlerinde artış olduğu görülmektedir. Ancak SpO₂ ölçümleri için aynı yorumu yapmak mümkün görünmemektedir.

Tablo 4.

Ortalama Fizyolojik Ölçümler

İş Grubu	Ortalama KAF	Ortalama Başlangıç SpO ₂	Ortalama Bitiş SpO ₂	Ortalama Kcal
Hafif	81,6	97	94,5	60
Orta	83,45	96,8	95,3	68,9
Ağır	84,4	97	96	68,67
Genel	83,3	97	95,2	67

Bu durumun nedenleri değerlendirildiğinde; Borg Skalası ile subjektif alınan ölçümler kaynaklı, işlerin gerçek zorluk derecesinin tam olarak kategorize edilememesi tespit edilmiştir.

4.2. Dinlenme Süresinin Tespiti

Fiziksel işte yorgunluk ölçümüne yönelik literatürde yer alan denklemler mevcuttur. Bu denklemler fiziksel işler için dinlenme süresi hakkında yorum yapmayı sağlamaktadır ancak zihinsel yorgunluk faktörünü öngörememektedir. Çalışma esnasında ve dinlenme esnasında fizyolojik ölçüm değerleri alınarak çalışanların harcadığı enerji miktarı makine öğrenmesi modeline tanıtılmaktadır. Ancak makine öğrenmesi modeli kurgulama sürecinde alınan verilerin nasıl yorumlanacağını da modele tanıtılması gereklidir. Bu kapsamda literatürde yer alan enerji formülleri incelenmiş ve bu formüllerde yer alan mola süresi hesaplamasının makine öğrenmesi modeli kurgusunda gerekli olduğu tespit edilmiştir.

Oksijeni kullanma maksimum kapasitesi (aerobik kapasite), VO_2max ölçümü genellikle laboratuvar ortamında gerçekleştirilen egzersiz testleri ile yapılmaktadır. Ancak, egzersiz testleri zaman ve ekipman gerektirdiğinden kalp atış frekansı (KAF) ölçümü ile Denklem 1 kullanılarak hesaplanabilmektedir.

HR_{max} : Maksimum KAF

$$HR_{max} = (200 - (0,65 \times \text{yaş}))$$

$HR_{at\ rest}$: Dinlenme anındaki KAF

olmak üzere VO_2max

$$VO_2 \max = 15.3 \times \left(\frac{HR_{max}}{HR_{at\ rest}} \right) \quad (1)$$

ifadesi ile hesaplanır (Bridger, 2017)

NIOSH maksimum iş kapasitesine göre dakikada harcanan enerji miktarı erkekler için 63 kJ/dk kadınlar için 44 kJ/dk olup, 1 litre oksijenin sağladığı enerji miktarı 20 kJ olarak alındığında; 1 dakikada alması gereken oksijen miktarı 3,15 L ve 2,2 L olarak tanımlanmıştır. Bu değerlere göre iş yükü hesaplaması gerçekleştirildiğinde; VO_2 değerleri 1 dakikada alınması gereken oksijen miktarına bölünerek yüzde olarak iş yükü düzeyi (p) bulunmaktadır (Bridger, 2017).

Dinlenme süresi;

w : çalışma süresi (saat)

b : oksijen alımı (VO_{2max}) (L/dak)

s : standart alım (L)

(vücut ağırlığı, cinsiyet ve yaş gibi faktörlere bağlı olarak sabit kabul edilir; NIOSH'un denklemine göre erkekler için 63, kadınlar için 44 kJ/min. 8 saatlik bir iş günü için maksimumun %33'ünü standart olarak alınırsa, iş yoğunlukları sırasıyla 21 ve 14,6 kJ/dak olur. 1 L oksijen yaklaşık 20 kJ enerji açığa çıkardığından bu grup için standart alım erkekler için 1,05 L ve kadınlar için 0,73 L olmaktadır.)

olmak üzere Denklem 2' ile hesaplanmaktadır (Bridger, 2017).

$$Dinlenme Süresi = \frac{w(b-s)}{b-0.3} \quad (2)$$

Belirtilen formüller kullanılarak her işlem (ve çalışan) için dinlenme süresi hesaplanmış ve değerler Tablo 5 'de verilmiştir.

Örnekleme amacıyla, Tablo 5'de yer alan ilk işlem (Aparat alıştırma) için;

$$HR_{max} = (200 - (0,65 \times 37)) = 175,95$$

$$HR_{at\ rest} : 83$$

$$VO_2\ max = 15.3 \times \left(\frac{175,95}{83}\right)$$

$$VO_2\ max = 32,4342\ (ml/kg/dak)$$

Bulunan $VO_2\ max$ değeri litre / dakika cinsinden vücut ağırlığına göre düzenlendiğinde;

$$VO_2\ max = (32,4342 * 0,001) * 70$$

$$VO_2\ max = 2,2704\ (L/dak)$$

olarak hesaplanabilmektedir.

Tablo 5.

İş Yüğü Düzeyi ve Dinlenme Süreleri

Gözlem No	İşlem Adı	Cinsiyet	Yaş	Kilo	HR _{max}	HR _{rest}	VO _{2Max} (ml/kg/dak)	Vücut Ağırlığına Göre Düzenlenmiş VO _{2max} (L/min)	Standart Oksijen Alımı	Dinlenme Süresi (dakika)
1	Aparat alıştırma	E	37	70	175,95	83	32,4342	2,2704	1,05	18,5809
2	Kesme çeliği alıştırma	E	31	75	179,85	62	44,3823	3,3287	1,05	22,5710
3	Kılavuz çekme	E	45	68	170,75	70	37,3211	2,5378	1,05	19,9456
4	Frezeleme	E	43	80	172,05	80	32,9046	2,6324	1,05	20,3531
5	Kalıp montajı	E	26	72	183,10	68	41,1975	2,9662	1,05	21,5611
6	Parlatma	K	24	77	184,4	76	37,1226	2,8584	0,73	24,9579
7	Malzeme montajı	K	25	62	183,75	74	37,9916	2,3555	0,73	23,7241
...										
110	Pas temizliği	E	53	80	165,55	62	40,8535	3,2683	1,05	22,4198

Aynı işlem için;

$$w : 0,5 \text{ (saat)}$$

$$b : 2,27 \text{ (L/dak)}$$

$$s : 1,05 \text{ (L)}$$

$$\text{Dinlenme Süresi} = \frac{0,5(2,27-1,05)}{2,27-0,3} = 0,31 \text{ saat} = 18,60 \text{ dk}$$

$$\text{İş Yüğü Düzeyi} = \frac{18,60}{3,15} = 0,72 = \%72$$

olarak bulunmaktadır (Türksever Dayal, 2024).

4.3 Makine Öğrenmesi Modellerinin Hazırlanması

Sayısal olarak toplanmış veriler birçok popüler programlama dilinin kullanılmasıyla makine öğrenmesi modellerine çevrilip, gelecekte toplanacak verilerin tahminlenmesi sağlanabilir. Bu çalışmada Phyton temelli uygulamalar kullanılarak makine öğrenmesi modellerinin eğitimi, veri tahmini ve verilerin makine öğrenmesi için hazırlık aşamaları gerçekleştirilmiştir. Çalışma kapsamında alınan veri seti üzerinden makine öğrenmesi modelleri oluşturulmuştur.

Algoritmalarından gelen iş yüğü düzeyi tahminlemeleri sonrası, tahminlerden hareketle mevcut çalışma ve mola sürelerine göre tahminlenen yeni mola süreleri oluşturulmuştur. Verilerin normalleştirilmesi, veri analizi ve makine öğrenmesi modellerinin kurgulanması alanlarında sıkça kullanılan bir tekniktir. Bu işlem, farklı özelliklere sahip veri noktalarını belirli bir aralığa veya dağılıma taşımak amacıyla yapılır. Normalleştirme işlemi, verilerin birbirleriyle karşılaştırılabilir hale gelmesini sağlar ve algoritmaların daha iyi performans göstermesine yardımcı olur (Sorhun, 2021).

Çalışma kapsamında Phyton yazılım dilinin kütüphanelerinden biri olan scikit-learn kütüphanesinin standart fonksiyonları kullanılarak verilerin normalleştirilmesi işlemi gerçekleştirilmiştir. Bu kütüphane aynı zamanda makine öğrenmesi modellerinin oluşturulmasında da kullanılmaktadır. Verileri açmak, işlemek ve kaydetmek için pandas kütüphanesinden faydalanılmıştır. Pandas kütüphanesi Phyton yazılım dilinde kullanılan veri analizi yapmayı sağlayan kütüphanedir. Veri normalleştirme sürecinde genel amaç, veri toplama sürecinde oluşan eksik ya da hatalı verilerin makine öğrenmesi modelinde sapmalara neden olmasını engellemektir.

Makine öğrenmesi algoritmasını kurarken temel amaç, olabildiğince hatasız şekilde hedef değişkenin tahmin edilebilmesini sağlamaktır. Dolayısıyla tahmin verilerinin ne kadar doğru olduğunu test edebilmek hem de modeli daha iyi


optimize edebilmek için veri setini gruplandırmamız gerekmektedir. Gözlem değerleri üzerinde modelleme yapmadan önce veriler 2 ayrı parçaya ayrılmaktadır. Çalışma verileri ve model iyileştirme verileri eğitim seti olarak adlandırılmaktadır. Eğitim verilerinin bir bölümü üzerinde model çalışmakta, diğer bölüm üzerinde model iyileştirilmektedir. Test verileri ile de model test edilmektedir. Gözlem/veri sayısına bağlı olarak en az %60 en fazla %90 olarak datadan eğitim için bölüm ayrılabilir (Şener, 2020). Veri seti öncelikle normalleştirilmiştir. Normalleştirme sonrası veriler incelendiğinde yalnızca 55 numaralı ölçümün normalleştirildiği gözlemlenmiştir. Bu durum veri setinin çoğunlukla normal dağılıma uyduğunu göstermektedir. Veriler normalleştirme işleminin ardından öncelikli olarak eğitim ve test verileri olarak iki gruba ayrılmıştır. Çalışma kapsamında, ayırma sürecinde verinin %72'lik dilimi eğitim verisi olarak ayrılmışken, kalan %28'luk veri seti test verisi olarak sınıflandırılmıştır. 110 katılımcıdan alınan verilerin 80 adedi eğitim veri seti, 30 adedi ise test verisi olarak gruplandırılarak değerlendirilmeye alınmıştır.

Girdi olarak kullanılan normalize edilmiş verilerin çıktısı; Denklem 2 ile elde edilen dinlenme süreleri olarak seçilmiştir. Verilerin modellenmesi ve tahminlemelerin yapılması Phyton tabanlı Orange platformunda yapılmıştır. Modellenen veriler tahminleme etabında farklı denetimli öğrenme algoritmaları ile test edilmiştir. Her yöntem sonrası tahmin değerlerinin bilinen gerçek değerlerle arasındaki farkları incelenerek model doğruluğu hesaplanmıştır.

4.4 Karar ağacı yöntemi ile mola süresinin tahmin edilmesi

Karar ağacı böl ve yönet yaklaşımından yararlanan hiyerarşik bir gözetimli öğrenme modeli, parametre gerektirmeden verimli bir şekilde sınıflandırma ve regresyon gerçekleştiren bir yöntemdir (Alpaydın, 2017). Karar ağacı karar ve bitiş düğümlerinden oluşur. Her bir karar düğümü dalları etiketleyen ayrık bir test fonksiyonunu gerçekleştirmektedir. Verilmiş bir girdiye bu test fonksiyonu uygulanmakta ve sonucuna göre girdiye uygun bir dal seçilmektedir. Bu süreç kökte başlayıp, özyinelemeli olarak bir bitiş düğümüne ulaşana kadar sürdürülmektedir. Böylece girdinin ait olduğu sınıf tespit edilmektedir (Kalaycı, 2018).

Normalleştirilmiş veri seti karar ağacı yöntemi ile eğitilerek mola süreleri hesaplanmıştır. Kök düğümünden yaprak düğüme giden yol uzunluğunun belirlenmesinde farklı denemeler gerçekleştirilerek 2, 5, 8, 9, 10, 20, 50 değerleri denenmiştir. Farklı dal uzunlukları denemelerinde 8 ve üzeri dallanmalarda doğruluk değeri %96 olarak bulunmuştur. Ancak her bir girişin hedef veriye olan etkisini kaybetmemek adına 10 seçilmiştir. Burada temel amaç çok büyük değer kullanarak veri setinin iyi öğrenmesini sağlamak ancak genelleme yeteneğini kaybetmemeye özen göstermektir. Karar ağacı ile yapılan tahminleme modelinde doğruluk oranı %96 olarak hesaplanmıştır. Şekil 2'de Karar ağacı algoritması ile oluşturulan tahmin modelinin ağaç görüntüsü verilmiştir.



Şekil 2. Kullanılan Karar Ağacı Modeli

Verilerin sonuçlara olan katkısını görebilmek amacıyla RRelieFF algoritmasından faydalanılmıştır. RRelieFF yöntemi, özelliklerin değerini aralarındaki bağımlılıkları ortaya çıkartmaya çalışarak bulmaktadır. Yöntem, ikili sınıflandırma problemlerinde özellik seçimi için kullanılmaktadır (Budak, 2018). RRelieFF algoritması, her özelliğin hedef değişkenle olan ilişkisini değerlendirerek en uygun özellikleri belirler. Bu, daha doğru tahminler yapabilen, daha hızlı çalışabilen ve daha iyi genelleme yapabilen modeller oluşturulmasına yardımcı olmaktadır. Şekil 3’de RRelieFF algoritması ile oluşturulan veri bileşenlerinin çıktıya olan katkısı görülmektedir.

	#	Univar. reg.	RRelieFF
1 N Scaled BORG Score		15.397	0.359
2 N Cleaned Blood O2 (başlangıç)		10.860	0.335
3 N Normalized Height (cm)		1.486	0.294
4 N Scaled REBA Score		3.558	0.260
5 N Normalized Age		0.000	0.255
6 N İş Yüğü (p)		7.050	0.252
7 N Cleaned Heart Rate (Ort)		0.002	0.184
8 N Cleaned Blood O2 (bitiş)		0.252	0.178
9 N Cleaned Heart Rate (Min)		0.361	0.177
10 N Avg. Blood O2 Drop		1.790	0.124
11 N Cleaned Heart Rate (Max)		0.027	0.119

Şekil 3. Verilerin Sonuçlara Olan Katkısı

Sonuçlar incelendiğinde maksimum kalp atış frekansının katsayısı (0.119) oldukça düşük iken Borg Skalası sonuçlarının katsayısının (0.359) oldukça yüksek olduğu görülmektedir. Bu durum karar ağacı yöntemi ile geliştirilen modelde Borg Skalasının modele katkısının oldukça yüksek olduğunu ancak kalp atış frekansının modele katkısının diğer verilere kıyasla düşük olduğunu göstermektedir.

4.5 Lineer Regresyon Yöntemi ile Mola Süresinin Tahminlenmesi

Makine öğrenmesi modellerinden biri olan Lineer Regresyon modelleri bağımsız değişkenlere dayanan bir hedef tahmin değerini modeller. Çoğunlukla değişkenler ve tahmin arasındaki ilişkiyi bulmak için kullanılmaktadır. Farklı regresyon modelleri, bağımlı ve bağımsız değişkenler, kullanılan bağımsız değişkenlerin sayısı arasındaki ilişkiye göre farklılık göstermektedir (Gültepe, 2019).

Regresyon modeli ile mevcut verilerden hareketle bir tahmin modeli oluşturulması amaçlanmıştır. Python temelli Orange platformunda kurgulanan regresyon modelinde oluşturulan denklemin katsayıları Şekil 4'de mevcuttur.

	name	coef
1	intercept	17.408
2	Cleaned Blood O2 (başlangıç)	0.00430221
3	Cleaned Blood O2 (bitiş)	0.040881
4	Cleaned Heart Rate (Max)	0.0239211
5	Cleaned Heart Rate (Min)	-0.0519505
6	Cleaned Heart Rate (Ort)	0.0116467
7	Avg. Blood O2 Drop	-0.0365788
8	Normalized Age	-0.28345
9	Normalized Height (cm)	0.112871
10	Scaled BORG Score	0.702682
11	Scaled REBA Score	0.01982
12	İş Yüğü (p)	0.604312

Şekil 4. Lineer Regresyon modelinde bulunan katsayılar

Oluşturulan regresyon modelinin bağımlı değişkeni mola süresidir. Regresyon modelinin katsayıları incelendiğinde sonuçlara en yüksek etkinin 0.702682

katsayısı ile Borg Skalası sonuçları olduğu görülmektedir. İkinci en büyük etkinin ise 0.604312 katsayısı ile iş yükü değerlerinin (p) olduğu görülmektedir. Borg Skalası, çalışanların subjektif fiziksel aktivite yoğunluğunu değerlendirmektedir. Kişiye özgüdür ancak işin zorluk düzeyi arttıkça skalanın da yükselmesi beklenir. İş yükü ise kişinin oksijen tüketimine bağlı bir parametre olduğundan, işin zorluk düzeyi arttıkça oksijen kullanım miktarı artar. Bu da iş yükü değerini yükseltir. Bu iki parametrenin mola süresinde oldukça etkili olduğu tespit edilmiştir.

Normalize edilmiş veriler ile çalıştırılan Lineer Regresyon modelinde %97 doğruluk oranı tespit edilmiştir. Doğruluk oranı, modelden elde edilen tahmin değeri ile, dinlenme süresi arasındaki mutlak farkın dinlenme süresine oranlanması ile hesaplanmıştır. Tüm veriler için hesaplanan hata oranlarının ortalaması, modelin hata ortalaması olarak bulunmuştur.

4.6 Yapay Sinir Ağları Yöntemi ile Mola Süresinin Tahminlenmesi

Yapay Sinir Ağları yönteminde ise veri seti ile Python temelli Orange kütüphanesinde model kurgulanarak çıktılar elde edilmiştir. Ancak model içinde eklenen verilerin çıktısı olan etkileri yapay sinir ağları ile oluşturulmuş modelde farklı bir dağılım göstermiştir. Diğer kullanılan modellerin aksine yapay sinir ağları ile oluşturulmuş modelde neredeyse bütün giriş verilerinin çıktısı etki ettiği gözlemlenmiştir. Ancak modelin doğruluk oranı %77 olarak hesaplanmıştır. Bu sonuç, kurgulanan diğer makine öğrenmesi modelleri ile karşılaştırıldığında en düşük doğruluk oranının yapay sinir ağı modelinde olduğunu göstermektedir.

4.7 Tahminlerin Değerlendirilmesi

80 veri ile eğitilen modelde 30 veri ile test gerçekleştirilerek alınan sonuçlar değerlendirilmiştir. Her model için, modelin hata oranı hesaplanarak en yüksek başarıya sahip model üzerinden çalışmaya devam edilmiştir. Hata değerleri iş yükünden hareketle hesaplanan mola süresi ile modelin tahminlediği mola süresi arasındaki farktır. Modelin hata oranı ise bu farkların ortalaması olarak hesaplanmaktadır. Üç farklı makine öğrenmesi modelinde 30 veri için yapılan tahminlemede elde edilen hata değerleri Şekil 5'de yer almaktadır. Modellerin hata oranları incelendiğinde, Lineer Regresyon ile yapılan modelleme %97 doğruluk oranı ile en başarılı tahmin modelini sağlarken, %77 doğruluk oranı ile en kötü tahmin modeli Yapay Sinir Ağları olmuştur. Bu nedenle dinlenme süresinin tahminlenmesi sürecinde doğruluk oranı en yüksek olan Lineer Regresyon modeli kullanılmıştır.

	Neural Network	error	Random Forest	error	Random Forest - tree 33	error	Linear Regression	error	İre Göre Dinlenme	OLÇUM NO:
1	31.3345	10.1604	21.0446	-0.129531	22.2056	1.03148	21.3589	0.184745	21.1741	81
2	31.8782	12.0798	21.0005	1.20206	22.2056	2.40716	21.3399	1.54142	19.7984	82
3	31.7629	10.5027	21.0258	-0.234435	22.2056	0.945416	21.1798	-0.0803528	21.2602	83
4	28.9791	7.00156	20.8859	-1.09165	20.1681	-1.80942	21.0045	-0.973073	21.9776	84
5	30.2192	8.63241	20.7885	-0.798296	21.16	-0.426845	21.2034	-0.383412	21.5868	85
6	27.2403	8.99784	21.1812	2.93873	22.2056	3.96311	21.644	3.40155	18.2425	86
7	28.0883	7.02685	21.2398	0.178351	22.2056	1.14416	21.3293	0.267834	21.0614	87
8	28.4998	6.51617	20.992	-0.991681	22.2056	0.221953	21.5713	-0.412316	21.9837	88
9	33.249	11.2195	20.928	-1.10153	22.2056	0.176114	21.5649	-0.464579	22.0295	89
10	29.9707	8.47919	20.927	-0.564485	21.16	-0.33154	21.0361	-0.455446	21.4915	90
11	25.3268	2.92902	20.5344	-1.86338	22.2056	-0.192153	21.3263	-1.07148	22.3978	91
12	25.3683	2.93121	20.9507	-1.48639	22.2056	-0.231471	22.2656	-0.171445	22.4371	92
13	28.9221	5.47186	21.1121	-2.3381	22.2056	-1.24464	21.2504	-2.19988	23.4502	93
14	28.9231	7.93437	21.0328	0.0439951	21.8365	0.847762	21.486	0.497179	20.9888	94
15	25.6657	4.33867	20.9091	-0.417939	21.8365	0.509465	20.2893	-1.03783	21.3271	95
16	26.3752	4.25964	21.1914	-0.924163	21.8365	-0.279023	21.7198	-0.395818	22.1156	96
17	23.7471	2.73271	20.5641	-0.450338	21.8365	0.822156	20.6117	-0.402642	21.0144	97
18	23.7504	0.540...	21.4079	-1.80169	23.3014	0.0917607	21.5244	-1.68525	23.2096	98
19	23.9745	1.05684	21.8079	-1.10975	22.2056	-0.712077	22.4669	-0.450735	22.9177	99
20	25.3487	4.1545	21.3973	0.203163	21.8365	0.642365	22.2243	1.03016	21.1942	100
21	21.8145	-1.03...	21.4909	-1.36155	21.8365	-1.0159	22.5767	-0.275755	22.8524	101
22	21.3438	-2.64...	21.9451	-2.04631	22.2056	-1.78585	23.1249	-0.866551	23.9915	102
23	22.2026	-0.48...	21.5221	-1.16673	21.8365	-0.852267	22.9175	0.228645	22.6888	103
24	23.5607	-0.18...	21.6046	-2.13896	21.8365	-1.90706	22.3414	-1.40219	23.7436	104
25	22.7458	-0.44...	21.4447	-1.74804	21.8365	-1.35616	22.8561	-0.336594	23.1927	105
26	23.2521	0.770...	21.6798	-0.801657	23.3014	0.819977	23.0002	0.518814	22.4814	106
27	22.6037	0.632...	21.519	-0.451898	21.8365	-0.134377	22.4976	0.526658	21.9709	107
28	25.9745	2.69837	21.9543	-1.32188	22.2056	-1.07056	23.4679	0.19173	23.2762	108
29	25.9916	2.53329	22.157	-1.30131	22.2056	-1.25266	23.2555	-0.202735	23.4583	109
30	29.4862	7.06634	21.4907	-0.929141	21.8365	-0.583302	22.6316	0.211726	22.4198	110

Şekil 5. Tahmin modelleri ve hesaplanan mola süreleri arası ilişki

Şekil 5' de görüldüğü üzere tahmin modellerinden alınan veriler ile VO_2max değerlerinden hareketle hesaplanan mola süreleri üzerinden atanan mola süreleri karşılaştırılmıştır. Hata sütununda ise modelde elde edilen tahmin değeri ile p değerlerinden hareketle elde edilen mola süreleri arasındaki fark mevcuttur. Bu değer makine öğrenmesi modellerinden gelen tahmin değerleri ile p değerinden hareketle elde edilen mola süreleri arasındaki fark işlemi ifade etmektedir ve makine öğrenmesi modelleri kurgulandıktan sonra Orange platformu aracılığıyla elde edilmiştir.

Tüm işler için mola süresi tahminlemeleri sonrası Borg Skalasına göre gruplandırılan işler için standart olarak belirlenmiş olan mola süreleri ve tahmin edilmiş olan mola süreleri arasındaki fark incelenmiştir. Her bir grup için (Hafif – Orta – Ağır) ayrı ayrı incelenmiş ve farklı zorluklardaki işlerin mola sürelerindeki optimizasyon değerleri ortaya koyulmuştur.

Borg Skalasına göre bölümlendirilmiş işler için üç makine öğrenmesi modeli ile bulunan mola süreleri analiz edilmiştir (Tablo 6). En yüksek doğruluk oranına sahip Lineer Regresyon modeline göre Hafif düzeyde çalışan işçiler için mola süresi mevcut mola süresinin 21,42 dakika, Orta düzeyde çalışan işçiler için 21,52 dakika ve Zor düzeyde çalışan işçiler için 22,87 dakika olarak tespit edilmiştir. İlgili süreler 30 veri ile test edilen Lineer Regresyon modelinin tahmin ettiği mola sürelerinin Borg Skalasına göre hafif, orta ve ağır olarak bölümlendirilmesi ardından, ilgili tahmin değerlerinin aritmetik ortalamasının

alınması ile bulunmuştur. Dinlenme süresi formülü ile hesaplanan mola süreleri ve modelin tahminlediği mola süreleri değerlendirildiğinde hafif düzeyde çalışanlar için mola süresinin 21,58 dakika, orta düzey zorluk derecesinde çalışanlar için mola süresinin 22,11 dakika ve ağır düzeyde çalışanlar için mola süresinin 23,01 dakika olması gerektiği görülmüştür. Bu durum mevcutta yapılan 15 dakikalık mola süresinin yetersizliğini teyit etmektedir.

Tablo 6.

Makine Öğrenmesi Modelleri ve Denklem 2 İle Hesaplanan Mola Sürelerinin Karşılaştırılması

İşlerin Zorluk Düzeyi	Yapay Sinir Ağları Modeli (dk)	Karar Ağacı Modeli(dk)	Lineer Regresyon Modeli(dk)	Dinlenme Süresi Formülü ile Bulunan Süreler (dk)
Hafif	27,93	21,96	21,42	21,58
Orta	25,74	22,13	21,52	22,11
Ağır	23,90	22,09	22,87	23,01

Sonuçlara bakıldığında Denklem 2 ile hesaplanan dinlenme süresine en yakın tahminin Lineer Regresyon modelinde çıktığı görülmektedir. Yapay sinir ağları ile oluşturulan modele göre, işlerin ağırlığının artışı ile mola süreleri arasında ters yönlü bir ilişki bulunmaktadır. Karar ağacı modelinde işlerin ağırlığı ile mola süresi arasında anlamlı bir ilişki görünmemektedir.

5. Sonuç ve Öneriler

Kalıp yapım atölyesinde sık tekrar edilen 110 iş belirlenerek, çalışanlardan pulsmetre ve akıllı saat yardımı ile fizyolojik veriler toplanmıştır. Çalışanların maruz kaldığı ergonomik risklerin belirlenmesi için REBA yöntemi, algılanan subjektif eforun ölçümü için ise Borg Skalasından yararlanılmıştır. Bu ölçümler ile makine öğrenmesi modelleri oluşturularak, dinlenme süresinin tahminlenmesi gerçekleştirilmiştir.

Kalıp imalatı üzerine çalışan işletmede farklı zorluk düzeylerinde yer alan birçok iş mevcuttur. Bu işler için tanımlı olan 15 dakikalık 2 molanın yeterliliğinin değerlendirildiği ve olması gereken mola süresinin tahminlenmesi üzerine gerçekleştirilen bu çalışma ile mevcut mola sürelerinin yeterliliği incelenmiş ve yeni mola süresinin tahminlenmesi gerçekleştirilmiştir. Bu çalışma kapsamında kalıp yapım sürecinde gerçekleştirilen ve tüm kalıp yapım süreçlerinde ortak olan 110 işlem belirlenerek, belirlenen işler için mola süresi tahminlenmesi; fizyolojik ölçüm yöntemleri, algılanan subjektif efor ve ergonomik risk skorlarını

dikkate alan makine öğrenmesi modelleri kurgulanmıştır. İş kanunun belirlediği yasal süreye göre mola sürelerini düzenleyen işletme için işleri 3 ana zorluk derecesine göre kategorilere ayırarak mevcut işlerin firma içindeki dağılımı belirlenmiştir.

Borg Skalası sonuçlarına göre mevcutta gerçekleştirilen işlerin %48,2'sinin orta ağırlıktaki işlerden oluştuğu belirlenmiştir. Mola sürelerinin tahminlenmesinde ergonomik risk değerlendirme skorları REBA yöntemi ile hesaplanarak modele dahil edilmiştir. Ergonomik risk skorları sonuçlarına göre %44,5'inin yüksek risk seviyesinde olduğu ve %9,3'ünün çok yüksek risk seviyesinde olduğu görülmektedir. Çalışanların bireysel farklılıklarını değerlendirme ölçütlerine dahil edebilmek için fizyolojik ölçümler; boy, kilo, cinsiyet, KAF, SpO₂, ve harcanan enerji miktarı kaydedilmiştir. Bu süreçte giyilebilir akıllı cihaz teknolojilerinden ve pulsmetre cihazından faydalanılmıştır. Bu bilgiler çalışanların kişisel farklılıklarını ortaya koymaktadır ve dinlenme sürelerinin hesaplanmasında metabolik farklılıkların modele dahil edilmesini sağlamıştır.

Çalışanlardan alınan ergonomik risk skorları, fizyolojik ölçümler ve Borg Skalası sonuçları ile makine öğrenmesi modelleri kurgulanmıştır. Geliştirilen model için 14 farklı özneliğe sahip 1540 veri kullanılmıştır. Farklı makine öğrenmesi metotları kullanılarak oluşturulan modellerde Lineer Regresyon yöntemi yüksek doğruluk oranı nedeniyle tercih sebebi olmuştur. Seçilen model sonrasında 3 farklı iş grubu için hazırlanan doğrulama verilerine göre tahminler gerçekleştirilmiştir. Her biri 10 adet işten oluşan 3 farklı zorluk kategorisi için modelin tekrar tahmin yapması sağlanmıştır. Yapılan çalışma sonuçlarına göre Hafif düzeyde çalışan işçiler için mola süresi mevcut mola süresinin 21,42 dakika, Orta düzeyde çalışan işçiler için 21,52 dakika ve Zor düzeyde çalışan işçiler için 22,87 dakika olarak tespit edilmiştir. Çıkan sonuçlar göstermektedir ki, farklı ağırlık düzeylerine sahip işler için mola süreleri de birbirinden farklı olmalıdır. Ancak tahmin sonuçları detaylı incelendiğinde tüm zorluk düzeyleri arasında gerekli minimum dinlenme sürelerinin arasındaki farkın oldukça az olduğunu söylemek mümkündür. Bunun nedeninin Borg Skalası ile subjektif alınan ölçümler kaynaklı, işlerin gerçek zorluk derecesinin tam olarak kategorize edilememesi olarak belirlenmiştir. Bu bağlamda, çalışanların algıladıkları subjektif eforun çalışmaya dahil edilmesi ile bazı gerçekleştirilen işlemlerin ağır grubundaki olması gerekirken orta yada benzer şekilde orta grupta yer alması gereken işlemlerin hafif grubuna yer aldığı çıkarımı yapılabilmektedir. Sonuçlar ışığında mola sürelerinin arttırılması gerektiği vurgulanarak bulunan sürelerin mola süresi olarak değerlendirilmesi firma yetkililerine önerilmiştir.

Gelecek çalışmalarda; 1540 veri ile kurgulanan makine öğrenmesi modeli, sayıca arttırılarak geliştirilebilir. Mevcutta atölye tipi üretim yapan işletmeden alınan veriler ile geliştirilen model, gelecek çalışmalarda üretim tipi farklı işletmeler için tekrarlanması fayda sağlayacaktır. Çalışma verileri değerlendirildiğinde, çalışmalarda cinsiyetler arası mola süresinin farkı üzerine ayrıca bir

değerlendirme yapılabilir. Farklı yaş grubundaki bireylerin ihtiyaç duyacağı mola sürelerinin incelenmesi üzerine çalışma gerçekleştirilebilir.

Teşekkür

Ölçümlerin alınması sürecindeki desteklerinden dolayı Elif Umay Göl'e, makine öğrenmesi modellerinin kurgulanması sürecindeki katkılarından dolayı Oğuz Alper İsen'e ve sürecin yönetimi için sağladığı desteklerinden dolayı Dr. Mehtap Hıdıroğlu ve Ozan Dayal'a teşekkür ederiz.

Araştırmacıların Katkısı

Bu araştırmada; Melis TÜRKSEVER DAYAL, bilimsel yayın araştırması, formların tasarımı, uygulanması, verilerin bilgisayara ortamına aktarılması, makine öğrenmesi modellerinin oluşturulması ve sonuçların yorumlanması; Emin KAHYA, bilimsel yayın araştırması, makalenin oluşturulması, makalenin sonuçlarının yorumlanması ve makalenin düzenlenmesi; N. Fırat ÖZKAN, modelin oluşturulması ve makine öğrenmesi modellerinin oluşturulması konularında katkı sağlamıştır.

Çıkar Çatışması

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir.

Kaynaklar

- Adem, A. ve Dağdeviren, M. (2021). A personnel scheduling model containing thermal comfort and equivalent metabolic rate factors. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36(1), 303-317. Erişim adresi : https://www.researchgate.net/profile/Metin-Dagdeviren-2/publication/346997976_A_personnel_scheduling_model_containing_thermal_comfort_and_equivalent_metabolic_rate_factors/links/61eeef8c5e3103375ba052a/A-personnel-scheduling-model-containing-thermal-comfort-and-equivalent-metabolic-rate-factors.pdf
- Akgül, M. N., Baltacı, S., Yıldız, K. C., Özcan, N. ve Akgül, M. Ş. (2021). Covid-19 pandemisinde pilates egzersizi sırasında cerrahi yüz maskesi takmanın etkilerinin Borg skalası özelinde değerlendirilmesi. *Akdeniz Spor Bilimleri Dergisi*, 4(2). 221-228. Doi : <https://doi.org/10.38021/asbid.941184>
- Alpaydın E. (2017). *Yapay Öğrenme*. Boğaziçi Üniversitesi Yayınevi.
- Altun, M., (2022). *Yapay Zeka ve Makine Öğrenmesi*. Milli Eğitim Bakanlığı.

- Alvarez-Garcia, J.A., Cvetkovi, B. ve Lustrek M., (2020). A survey on energy expenditure estimation using wearable devices. *ACM Computing Surveys*, 53(5), 1-35. Doi : <https://doi.org/10.1145/3404482>
- Arslan, K. (2020). Eğitimde yapay zeka ve uygulamaları. *Batı Anadolu Eğitim Bilimleri Dergisi*, 11 (1). 71-88. Erişim adresi : <https://dergipark.org.tr/en/download/article-file/1174773>
- Bent, B., Goldstein, B. A., Kibbe, W. A. ve Dunn, J. P. (2020). Investigating sources of inaccuracy in wearable optical heart rate sensors. *NPJ Digital Medicine*. 3(1), 18. Erişim adresi : <https://www.nature.com/articles/s41746-020-0226-6>
- Biamonte, J., Wittek, P., Pancotti, N., Rebentrost, P., Wiebe, N. ve Lloyd, S. (2017). Quantum machine learning. *Nature*, 549(7671). 195-202. Doi : <https://doi.org/10.1038/nature23474>
- Bridger, R. (2017). *Introduction to Human Factors and Ergonomics*. CRC Press.
- Budak, H. (2018). Özellik seçim yöntemleri ve yeni bir yaklaşım. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22, 21-31. Erişim adresi : <https://dergipark.org.tr/en/download/article-file/552933>
- Burdon J.G, Juniper E.F, Killian K.J, Hargreave F.E ve Campbell E.J. (1982). The perception of breathlessness in asthma. *The American Review of Respiratory Disease*, 126 (5). 825-828. Erişim adresi: <https://www.atsjournals.org/doi/abs/10.1164/arrd.1982.126.5.825>
- Chen, L. ve Wang, S. (2019). Predicting human energy expenditure using wearable sensors and machine learning. *Sensors*, 19(8). 1785. Doi : <https://doi.org/10.3390/s19081785> .
- Chen, Y., Liu, S. ve Wang, Y. (2020). A review on energy consumption prediction in manufacturing industry using machine learning techniques. *IEEE Access*, 8, 182032-182048. Doi : <https://doi.org/10.1109/ACCESS.2020.3028641>
- Chinnamgari, S. K. (2019). *R Machine Learning Projects: Implement supervised, unsupervised, and reinforcement learning techniques using R*. Packt Publishing Ltd. Erişim adresi: https://books.google.com.tr/books?hl=tr&lr=id=4dKDDwAAQBAJoi=fndpg=PP1dq=R+Machine+Learning+Projects:+Implement+supervised,+unsupervised,+and+reinforcement+learning+techniques+using+Rots=pyq050fUrBsig=yufYSCHjIIW2-264AqFINKSj-aUredir_esc=y#v=onepageq=R%20Machine%20Learning%20Projects%3A%20Implement%20supervised%2C%20unsupervised%2C%20and%20reinforcement%20learning%20techniques%20using%20Rf=false
- Cord, M. ve Cunningham, P. (Eds.). (2008). *Machine learning techniques for multimedia: case studies on organization and retrieval*. Springer Science & Business Media.

- Chow, H. W. ve Yang, C. C. (2020). Accuracy of optical heart rate sensing technology in wearable fitness trackers for young and older adults: validation and comparison study. *JMIR mHealth and uHealth*, 8(4). e14707. Doi : <https://doi.org/10.2196/14707>
- Dolgui A. ve Proth J.M., (2010). Pricing strategies and models, *Annual Reviews in Control*. 34(1). 101-110. Doi : <https://doi.org/10.1016/j.arcontrol.2010.02.005>
- Dohyung, K. (2021). Comparison of OWAS, RULA and REBA for assessing potential work-related musculoskeletal disorders, *International Journal of Industrial Ergonomics*, 83,103140. Doi : <https://doi.org/10.1016/j.ergon.2021.103140>
- Frasie, A., Bertrand-Charette, M., Compagnat, M., Bouyer, L. J. ve Roy, J. S. (2024). Validation of the Borg CR10 Scale for the evaluation of shoulder perceived fatigue during work-related tasks. *Applied Ergonomics*, 116, 104200. Doi : <https://doi.org/10.1016/j.apergo.2023.104200>
- Friedl, M. A., Brodley, C. E. (1997). Decision tree classification of land cover from remotely sensed data. *Remote Sensing Of Environment*, 61(3). 399-409. Doi : [https://doi.org/10.1016/S0034-4257\(97\)00049-7](https://doi.org/10.1016/S0034-4257(97)00049-7)
- Gillinov, S., Etiwy, M., Wang, R., Blackburn, G., Phelan, D., Gillinov, A. M., ... Desai, M. Y. (2017). Variable accuracy of wearable heart rate monitors during aerobic exercise. *Medicine Science in Sports Exercise*, 49(8). 1697-1703. Doi : <https://doi.org/10.1249/MSS.0000000000001284>
- Gültepe, Y. (2019). Makine öğrenmesi algoritmaları ile hava kirliliği tahmini üzerine karşılaştırmalı bir değerlendirme. *Avrupa Bilim ve Teknoloji Dergisi*, (16). 8-15. Doi : <https://doi.org/10.31590/ejosat.530347>
- Gürsakil, N. (2017). *Makine Öğrenmesi ve Derin Öğrenme*. Dora Basım.
- Hignett, S. ve McAtamney, L. (2000). Rapid Entire Body Assessment (REBA). *Applied Ergonomics*, 31(2). 201-205. Doi: [https://doi.org/10.1016/S0003-6870\(99\)00039-3](https://doi.org/10.1016/S0003-6870(99)00039-3)
- Jachymek, M., Jachymek, M. T., Kiedrowicz, R. M., Kajmierczak, J., Pjojska-Gozciniak, E. ve Peregud-Pogorzelska, M. (2021). Wristbands in home-based rehabilitation-Validation of heart rate measurement. *Sensors*, 22(1). 60. Doi : <https://doi.org/10.3390/s22010060>
- Janiesch, C., Zschech, P. ve Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3). 685-695. Doi : <https://doi.org/10.1007/s12525-021-00475-2>
- Jiao, Z., Huang, K., Wang, Q., Jia, G., Zhong, Z. ve Cai, Y. (2024). Improved REBA: Deep learning based rapid entire body risk assessment for prevention of musculoskeletal disorders. *Ergonomics*, 67(10), 1356-1370. Doi : <https://doi.org/10.1080/00140139.2024.2306315>

- Kahya, A., Recal, A., Sevincer, Y., Gündüz, T. ve Özmutlu, S. (2021). Evalution of Physical and Mental Fatigue in an Assembly Line. *Journal of Industrial Engineering*, 32(3). 380-395. Erişim adresi : <https://dergipark.org.tr/en/pub/endustrimuhendisligi/issue/66238/823892>
- Kahya, E., Alpaslan, K. ve Şenyüz, G. (2023). Bir metal sanayi işletmesinde ergonomik risk değerlendirme yöntemleriyle bütünleşik iş yüklerinin analizi. *Eskişehir Osmangazi Üniversitesi Mühendislik Ve Mimarlık Fakültesi Dergisi*, 31(3), 848-861. Doi : <https://doi.org/10.31796/ogummf.1316286>
- Kahya, E., Özgen, C. ve Jorayeva, N. (2024). ergonomik risk değerlendirme yöntemleriyle tespit edilmiş fiziksel iş yükü ile enerji tüketiminin değerlendirilmesi. *Eskişehir Osmangazi Üniversitesi Mühendislik Ve Mimarlık Fakültesi Dergisi*, 32(2), 1315-1325. Doi : <https://doi.org/10.31796/ogummf.1429508>
- Kalaycı, T. E. (2018). Kimlik hırsız web sitelerinin sınıflandırılması için makine öğrenmesi yöntemlerinin karşılaştırılması. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 24(5). 870-878. Erişim adresi : <https://dergipark.org.tr/tr/pub/pajes/issue/39683/469468>
- Kansu, S., Parlak, T. ve Güneri, A. F. (2021). Kaynak işlemlerinde çalışan personel için reba metodu ile ergonomik risk değerlendirmesi: Kriyojenik tank imalatı sektöründe bir uygulama. *Mühendislik Bilimleri ve Tasarım Dergisi*, 9(3). 952-968. Doi : <https://doi.org/10.21923/jesd.872665>
- Kara, D. ve Yıldız, H. (2013). Dispne semptomunun değerlendirilmesinde dispne ölçeklerinin etkinlikleri ve kullanım sıklıkları. *Gümüşhane Üniversitesi Sağlık Bilimleri Dergisi*, 2(1). 137-149. Erişim adresi : <https://dergipark.org.tr/en/pub/gumussagbil/issue/7505/98941>
- Kim, C., Kim, S. H. ve Suh, M. R. (2022). Accuracy and validity of commercial smart bands for heart rate measurements during cardiopulmonary exercise test. *Annals of Rehabilitation Medicine*, 46(4). 209. Doi : <https://doi.org/10.5535/arm.22050.e>
- Kul, S., Atıcı Uslu, H. ve Gündüz, T., (2022). Bir tekstil işletmesinde proses kontrol personellerinin hata tespit davranışlarının bilişsel ve fiziksel iş yükü ile değerlendirilmesi. *Journal of Industrial Engineering*, 33(2). 309-322. Doi : <https://doi.org/10.46465/endustrimuhendisligi.1311373>
- Kumar, N., Venkatachalam, S., Subramaniam, S., Nithyaprakash, R., Elavarasan, A. J., Krishnashankar, E., ... Prakash, C. (2023). Ergonomic evaluation of different working posture and handle designs of mason trowel during wall plastering work based on shoulder and arm muscle activity. *Journal of Scientific Industrial Research*. 82(9). 938-946. Doi : <https://doi.org/10.56042/jsir.v82i9.4009>

- Li, Q., Wang, Y. ve Wang, Z., (2018). Predictive maintenance and energy efficiency in manufacturing: A review of machine learning applications. *Journal of Manufacturing Systems*, 48, 111-122. Doi : <https://doi.org/10.1016/j.jmsy.2018.06.012>
- Li, W. ve Zhang, Z. (2018). Energy expenditure prediction models in physical activity recognition systems: A systematic review. *IEEE Transactions on Industrial Informatics*, 14(5). 2206-2216. Doi: <https://doi.org/10.1109/TII.2018.2800919>
- Lindegård, A., Grimby-Ekman, A., Wahlström, J. ve Gustafsson, E. (2024). Can biofeedback training in combination with ergonomic information reduce pain among young adult computer users with neck and upper extremity symptoms?-A randomized controlled intervention study. *Applied Ergonomics*, 114, 104155, Doi : <https://doi.org/10.1016/j.apergo.2023.104155>
- Mert, U., İde, D. ve Gündüz, T. (2022). Otomotiv sektörü progresif kalıp hattında ergonomik üretim tasarımı ile verimliliğin artırılması. *Endüstri Mühendisliği*, 33(2). 289-308. Doi : <https://doi.org/10.46465/endustrimuhendisligi.1037667>
- Monkeylearn. (2021). *An Introduction to Machine Learning*. Erişim adresi : <https://monkeylearn.com/machine-learning/>.
- O'Driscoll, R., Turicchi, J., Hopkins, M., Duarte, C., Horgan, G. W., Finlayson, G. ve Stubbs, R. J. (2021). Comparison of the validity and generalizability of machine learning algorithms for the prediction of energy expenditure: validation study. *JMIR mHealth and uHealth*, 9(8). Doi : <https://doi.org/10.2196/23938>
- Pasadyn, S. R., Soudan, M., Gillinov, M., Houghtaling, P., Phelan, D., Gillinov, N. ve Desai, M. Y. (2019). Accuracy of commercially available heart rate monitors in athletes: a prospective study. *Cardiovascular Diagnosis And Therapy*, 9(4). 379. Doi : <https://doi.org/10.21037/cdt.2019.06.05>
- Perez, A.C., Roman, P.A.L., Jimenez, M.M., Zurita, M.L., Aguilera, J.A.L., Montilla, J.A.P. ve Lineras, J.C.C., (2022). Is the Xiaomi Mi Band 4 an accuracy tool for measuring health-related parameters in adults and older people an original validation study. *Int. J. Environ. Res. Public Health*, 19(3). 1593. Doi : <https://doi.org/10.3390/ijerph19031593>
- Ray, S. (2019). A quick review of machine learning algorithms. In *2019 International conference on machine learning, big data, cloud and parallel computing (COMITCon)*. IEEE, 35-39. Doi : <https://doi.org/10.1109/COMITCon.2019.8862451>
- Sağıroğlu, H., Coşkun, M.B. ve Erginel, N. (2015). REBA ile bir üretim hattındaki iş istasyonlarının ergonomik risk analizi. *Mühendislik Bilimleri ve Tasarım Dergisi*, 3(3). 339-345. Doi : <https://doi.org/10.21923/MBTD.81484>

- Simon, S., Dully, J., Dindorf, C., Bartaguiz, E., Becker, S. ve Fröhlich, M. (2024). Impact of fatigue on ergonomic risk scores and foot kinetics: a field study employing inertial and in-shoe plantar pressure measurement devices. *Sensors*, 24(4). 1175. Doi : <https://doi.org/10.3390/s24041175>
- Smith, J. ve Doe, R. (2020). A review on machine learning approaches for predicting human energy expenditure. *Journal of Artificial Intelligence and Energy Systems*, 12(3). 45-62. Doi : <https://doi.org/10.1249/MSS.0b013e31825e825a>
- Sorhun, E. (2021). *Python ile Makine Öğrenmesi*. Abaküs Kitap Yayın Eğitim.
- Şener, Y. (2020). *Makine Öğrenmesinde Train, Validation ve Test Kavramları ile Python Uygulaması*. Erişim adresi : <https://yigitsener.medium.com/makine-%C3%B6%C4%9Frenmesinde-train-validation-ve-test-kavramlar%C4%B1-ile-python-uygulamas%C4%B1-a60214fb5448>
- Türksever Dayal, M. (2024). *Fiziksel iş yüküne bağlı olarak mola süresinin makine öğrenmesi ile tahmin edilmesi* (Yüksek Lisans Tezi). Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü, Eskişehir.
- Vafeiadis, T., Diamantaras, K. I., Sarigiannidis, G. ve Chatzisavvas, K. C. (2015). A comparison of machine learning techniques for customer churn prediction. *Simulation Modelling Practice and Theory*, 55, 1-9. Doi : <http://dx.doi.org/10.1016/j.simpat.2015.03.003>
- Wang, H., Lu, X. ve Zhao, S., (2021). Predictive analytics for energy consumption in manufacturing: a comprehensive review. *Energy and AI*, 6, 100047. Doi : <https://doi.org/10.1016/j.egyai.2021.100047>
- Yapıcı, F. ve Öztonga, E. (2025). A new scoring system for the Rapid Entire Body Assessment (REBA) based on fuzzy logic: A case study. *Endüstri Mühendisliği*, 36(1), 86-101. Doi : <https://doi.org/10.46465/endustrimuhendisligi.1673565>
- Yıldız, B., Akın, N.M., Aydın, F., Gündüz, T. ve Özalp, B.T. (2022) Tekrarlı manual işlerde fizyolojik yükün metabolik hız modellemesi ile analizi. *Journal of Industrial Engineering*, 33(2). 309-322. Doi : <https://doi.org/10.46465/endustrimuhendisligi.1054341>
- Zhu, X. ve Goldberg, A. B. (2009). Introduction to semi-supervised learning. *Synthesis lectures on artificial intelligence and machine learning*. 3(1). 1-130. Erişim adresi : https://www.morganclaypoolpublishers.com/catalog/Orig/samples/9781627056083_sample.pdf.