OTOMOBİL SÜRÜCÜLERİNİN FARKLI TRAFİK VE YOL KOŞULLARINDAKİ BİLİŞSEL YÜKLERİNİN ARAŞTIRILMASI

Hilal ATICI ULUSU

T.C.
BURSA ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

OTOMOBİL SÜRÜCÜLERİNİN FARKLI TRAFİK VE YOL KOŞULLARINDAKİ BİLİŞSEL YÜKLERİNİN ARAŞTIRILMASI

Hilal ATICI ULUSU
0000-0001-8347-0806

Prof. Dr. Tülin GÜNDÜZ
(Danışman)

DOKTORA TEZİ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

BURSA – 2024
Her Hakkı Saklıdır.

ÖZET

Doktora Tezi

OTOMOBİL SÜRÜCÜLERİNİN FARKLI TRAFİK VE YOL KOŞULLARINDAKİ BİLİŞSEL YÜKLERİNİN ARAŞTIRILMASI

Hilal ATICI ULUSU

Bursa Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Endüstri Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Tülin GÜNDÜZ

Bu tez çalışmasının amacı farklı trafik yoğunluğu, yol tipi ve kişisel özelliklerin otomobil sürücülerinin zihinsel iş yükleri üzerinde yarattığı etkinin araştırılmasıdır. Sürücülerin zihinsel iş yükleri elektroensefalografi (EEG) sinyallerinden hesaplanan bant gücü ve indeks değerleri ile sayısal olarak ortaya koyulmuş, algılanan iş yükü NASA Görev Yükü İndeksi (NASA-TLX) ile sübjektif olarak da ölçülmüştür. Çalışmadaki sürüş deneyleri gerçek trafik ortamında 39 katılımcı ile belirli bir rota üzerinde gerçekleştirilmiştir. Alfa, teta, beta bant gücü ve mental durum indeksleri sakin hal ve sürüş arasında anlamlı farklılık göstermiştir. Kadın sürücülerin zihinsel iş yükü erkeklere göre daha yüksek bulunmuştur. Otuz yaş altı genç sürücülerin daha az zihinsel iş yüküne sahip olduğu görülmüştür. Ayrıca otomobil sürme tecrübesi yirmi yıl ve üzerinde olan sürücülerin, daha az tecrübeli sürücülere göre zihinsel olarak daha az zorlandığı tespit edilmiştir. Gerçek trafikteki sürüş verileri üzerinde istatistiksel çıkarımlar gerçekleştirildikten sonra makine öğrenmesi modelleri kullanılarak sürücülerin zihinsel iş yükünün sınıflandırılması amaçlanmıştır. EEG bant güçleri, EEG tabanlı mental durum indeksleri ve bireysel faktörlerin öznitelik olarak kullanıldığı ve zihinsel iş yükünün trafik yoğunluğu ve yol tipine göre etiketlendiği iki farklı veri kümesi oluşturulmuştur. Karşılıklı Bilgi (MI) ve Temel Bileşen Analizi (PCA) yöntemleriyle öznitelik seçimi yapılmış, ardından Destek Vektör Makineleri (SVM), k En Yakın Komşu Algoritması (kNN), Rassal Orman (RO) ve Yapay Sinir Ağı (YSA) modelleriyle zihinsel iş yükü sınıflandırılmıştır. Sınıflandırmada iki yaklaşım benimsenmiştir: Katılımcılar-arası ve katılımcı-bazında sınıflandırma. Katılımcılar-arası sınıflandırmada iki veri kümesi için en etkili öznitelikler frontal bölgedeki teta bant güçleri olmuştur. Trafik yoğunluğuna göre etiketlenen veri üzerinde en iyi sınıflandırma performansını %78,62 doğruluk değerine ulaşan PCA-RO modeli vermiştir. Yol tipine göre etiketlenen veri kümesinde ise öznitelik seçimi olmadan RO modeli %86,24 doğruluk ile en iyi sonucu vermiştir. Katılımcı-bazında sınıflandırmada her sürücü için zihinsel iş yükünü sınıflandırmada en etkili olan öznitelikler değişkenlik göstermiştir. Katılımcı-bazında trafik yoğunluğuna ve yol tipine göre etiketlenen veri kümeleri için en yüksek doğruluk değerleri sırasıyla %96,51 ve %98,06 olarak bulunmuştur.

Anahtar Kelimeler: Nöroergonomi, otomobil sürücüsü, elektroensefalografi, bilişsel yük, mental iş yükü, makine öğrenmesi
2024, vii + 113 sayfa.

ABSTRACT

PhD Thesis

INVESTIGATION OF DRIVERS' COGNITIVE LOADS IN DIFFERENT TRAFFIC AND ROAD CONDITIONS

Hilal ATICI ULUSU

Bursa Uludağ University
Graduate School of Natural and Applied Sciences
Department of Industrial Engineering

Supervisor: Prof. Dr. Tülin GÜNDÜZ

This thesis aims to investigate the effects of different traffic densities, road types and personal characteristics on the mental workload of automobile drivers. The mental workload of the drivers was revealed numerically with band power and index values calculated from electroencephalography (EEG) signals, and the perceived workload was also measured subjectively with the NASA Task Load Index (NASA-TLX). The driving experiments in this study were carried out in a real traffic environment with 39 participants on a specific route. Alpha, theta, beta band powers and mental state indices showed significant differences between relaxing state and driving session. The mental workload of female drivers was found to be higher than that of men. It was observed that young drivers under the age of thirty have less mental workload. In addition, it was determined that drivers with twenty years or more of driving experience have less mental workload than less experienced drivers. After performing statistical inferences on driving data in real traffic, it was aimed to classify the mental workload of drivers using machine learning models. Two different datasets were created in which EEG band powers, EEG-based mental state indices and individual factors were used as features and mental workload was labeled according to traffic density and road type. Feature extraction was made using Mutual Information (MI) and Principal Component Analysis (PCA) methods, and then mental workload was classified using Support Vector Machines (SVM), k Nearest Neighbor Algorithm (kNN), Random Forest (RF) and Artificial Neural Network (ANN) models. Two approaches were adopted in classification: Cross-subject and per-subject classification. The most effective features for the two datasets in cross-subject classification were theta band powers in the frontal region. The PCA-RF model gave the best classification performance on data labeled according to traffic density, reaching an accuracy value of 78.62%. In the dataset labeled according to road type, the RF model without feature selection gave the best result with an accuracy of 86.24%. In per-subject classification, the features that were most effective in classifying mental workload varied for each driver. The highest accuracy values for per-subject datasets labeled according to traffic density and road type were found to be 96.51% and 98.06%, respectively.

Key words: Neuroergonomics, automobile driver, electroencephalography, cognitive load, mental workload, machine learning
2024, vii + 113 pages.

TEŞEKKÜR

Doktora eğitimim boyunca bana her anlamda destek olan ve her zaman destek olacağını bildiğim danışman hocam sayın Prof. Dr. Tülin GÜNDÜZ'e; tez izleme komitemde yer alarak kıymetli bilgi ve tecrübelerini paylaşan, desteklerini esirgemeyen hocalarım sayın Doç. Dr. Demet GÖNEN OCAKTAN ve sayın Dr. Öğr. Üyesi Besim Türker ÖZALP'e en içten teşekkürlerimi sunarım. Tüm eğitim hayatım boyunca bana katkı sağlayan, üzerimde emeği bulunan tüm hocalarıma teşekkürlerimi sunarım.

Tez çalışması kapsamında gerçekleştirdiğimiz araştırma projesinde yer alan ve değerli bilgi ve tecrübeleriyle çalışmama katkı sağlayan hocalarım sayın Doç. Dr. İlker KÜÇÜKOĞLU ve sayın Doç. Dr. Özlem TAŞKAPILIOĞLU'na; tez savunma sınavımda yer alarak kıymetli görüşlerini paylaşan sayın hocam Doç. Dr. Necmettin Fırat ÖZKAN'a teşekkür ederim. Çalışmadaki makine öğrenmesi modellerinin uygulama aşamasında destek veren Arş. Gör. Esra KAVALCI YILMAZ'a teşekkür ederim.

Her zaman yanımda olduğunu bildiğim dostum Cemile DURMUŞ'a; doktora eğitiminin zorlu aşamalarını birlikte aştığımız arkadaşlarım Dr. Öğr. Üyesi Aslı SEBATLI SAĞLAM, Zeynep ÜSTÜNEL ve Elif KAYMAZ'a teşekkür ederim.

Tez çalışmamda gerçekleştirdiğim sürüş deneylerine kendi otomobilleriyle gönüllü olarak katılan tüm katılımcılara değerleri zamanlarını ayırdıkları için teşekkürlerimi sunarım.

Bu tez çalışması, Bursa Uludağ Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından FGA-2021-415 numaralı Genel Araştırma Projesi kapsamında desteklenmiştir. Bursa Uludağ Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi'ne destekleri için teşekkür ederim.

Son ve en önemli olarak, bana her zaman inanan, sevgi ve desteklerini esirgemeyen annem Perihan ATICI ve babam İlhan ATICI'ya, kardeşlerim Yıldız ATICI ve Yiğit ATICI'ya, geniş ailemdeki adını sayamadığım tüm sevdiklerime çok teşekkür ederim. Beni desteklemek için her zaman elinden gelenin en iyisini yapan, hep yanımda olan sevgili eşim Bahadır ULUSU'ya teşekkür ederim. Varlığı başlıca şükür sebebim olan, biricik kızım Bilge ULUSU'ya, bana en büyük desteği ve motivasyonu sağladığı için çok teşekkür ederim.

Hilal ATICI ULUSU
04/03/2024

İÇİNDEKİLER

Sayfa

ÖZET i
ABSTRACT ii
TEŞEKKÜR iii
SİMGELER ve KISALTMALAR DİZİNİ v
ŞEKİLLER DİZİNİ vi
ÇİZELGELER DİZİNİ vii
1. GİRİŞ 1
2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI 6
2.1. Nöroergonomi 6
2.2. Mental İş Yükü 9
2.3. Otomobil Sürücülerinin Mental İş Yükü 16
3. MATERYAL ve YÖNTEM 28
3.1. Veri Toplama Aşaması 28
3.1.1. NASA Görev Yükü İndeksi (NASA-TLX) 28
3.1.2. Elektroensefalografi (EEG) 30
3.2. Katılımcılar 33
3.3. Deneysel Prosedür 34
3.4. EEG Veri Analizi 38
3.4.1. EEG sinyal kalitesi 38
3.4.2. EEG tabanlı mental durum indeksleri 39
3.5. Mental iş yükü sınıflandırma aşaması 41
4. BULGULAR 49
4.1. Katılımcılar 49
4.2. EEG Veri Analizi 50
4.3. NASA-RTLX ve Zihinsel Zorluk Skoru Analizi 57
4.4. Trafik ve Yol Koşullarının Mental İş Yükü Üzerindeki Etkisi 60
4.5. Bireysel Faktörlerin Mental İş Yükü Üzerindeki Etkisi 61
4.5.1. Cinsiyet 61
4.5.2. Yaş 62
4.5.3. Otomobil sürme tecrübesi 63
4.6. Mental İş Yükü Sınıflandırma Sonuçları 65
4.6.1. Katılımcılar-arası mental iş yükü sınıflandırma sonuçları 65
4.6.2. Katılımcı-bazında mental iş yükü sınıflandırma sonuçları 71
5. TARTIŞMA VE SONUÇ 75
KAYNAKLAR 81
EKLER 89
EK 1 NASA-RTLX Uygulama Sayfası 90
EK 2 Katılımcı Bilgi ve Onay Formu 91
EK 3 Katılımcı-Bazında Veri Kümeleri 1 için Optimal Parametreler 92
EK 4 Katılımcı-Bazında Veri Kümeleri 2 için Optimal Parametreler 95
EK 5 Katılımcı-Bazında Veri Kümeleri 1 için Model Performansları 98
EK 6 Katılımcı-Bazında Veri Kümeleri 2 için Model Performansları 104
ÖZGEÇMİŞ 110

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler	Açıklama
EL	Çaba
W_{EL}	Çaba Alt Faktörünün Ağırlığı
PD	Fiziksel Talep
W_{PD}	Fiziksel Talep Alt Faktörünün Ağırlığı
k_{MI}	Karşılıklı Bilgi Yöntemi ile Seçilen Öznitelik Sayısı
FL	Kaygı
W_{FL}	Kaygı Alt Faktörünün Ağırlığı
PL	Performans
W_{PL}	Performans Alt Faktörünün Ağırlığı
k_{PCA}	Temel Bileşen Analizi Yöntemi ile Seçilen Öznitelik Sayısı
TD	Zamansal Talep
W_{TD}	Zamansal Talep Alt Faktörünün Ağırlığı
MD	Zihinsel Talep
W_{MD}	Zihinsel Talep Alt Faktörünün Ağırlığı

Kısaltmalar	Açıklama
CNN	Evrişimli Sinir Ağı (Convolutional Neural Network)
EEG	Elektroensefalografi
EKG	Elektrokardiyografi
EOG	Elektrookulografi
ERP	Olaya İlişkin Potansiyel (Event Related Potential)
fMRI	Fonksiyonel Manyetik Rezonans Görüntüleme
fNIRS	Fonksiyonel Yakın Kızılötesi Spektroskopisi
ICA	Bağımsız Bileşen Analizi (Independent Component Analysis)
KAF	Kalp Atış Frekansı
kNN	K En Yakın Komşu (K Nearest Neighbor)
LDA	Lineer Diskriminant Analizi
LSTM	Uzun Kısa Süreli Bellek (Long Short Term Memory)
MI	Karşılıklı Bilgi (Mutual Information)
MLP	Çok Katmanlı Algılayıcı (Multilayer Perceptron)
NASA-TLX	NASA Görev Yükü İndeksi (NASA Task Load Index)
NASA-RTLX	NASA Ham Görev Yükü İndeksi (NASA Raw Task Load Index)
PCA	Temel Bileşenler Analizi (Principal Component Analysis)
PET	Pozitron Emisyon Tomografisi
ReLU	Doğrusal Birim Aktivasyon Fonksiyonu (Rectified Linear Unit)
RO	Rassal Orman
SOM	Özdüzenleyici Haritalar (Self Organizing Maps)
SVM	Destek Vektör Makineleri (Support Vector Machines)
SWAT	Subjektif İş Yükü Değerlendirme Tekniği (Subjective Workload Assessment Technique)
VBA	Visual Basic for Applications
YSA	Yapay Sinir Ağları

ŞEKİLLER DİZİNİ

		Sayfa
Şekil 2.1.	Nöroergonomi araştırmalarının gelişimi.....	7
Şekil 2.2.	Bilişsel yük faktörleri ile bilişsel yük kategorileri arasındaki ilişkiler.....	10
Şekil 2.3.	Mental iş yükü ölçüm yöntemleri.....	11
Şekil 2.4.	Zamana göre mental iş yükünün farklı düzeyleri.....	12
Şekil 3.1.	Beyin dalgaları.....	31
Şekil 3.2.	Elektrotların yerleşimi.....	32
Şekil 3.3.	Deney rotası.....	35
Şekil 3.4.	Deneysel prosedür.....	36
Şekil 3.5.	Deneylerden görüntüler.....	37
Şekil 3.6.	Bağlantı ve sinyal kalitelerinin kontrolü.....	39
Şekil 3.7.	EEG sinyalleri ve makine öğrenmesi ile mental iş yükü sınıflandırma süreci.....	42
Şekil 3.8.	İki farklı veri etiketleme yaklaşımı ile oluşturulan veri kümeleri ve özellikleri.....	44
Şekil 3.9.	Çalışmanın genel gösterimi.....	48
Şekil 4.1.	Katılımcı demografik bilgilerinin dağılımı.....	49
Şekil 4.2.	Bant gücü değerlerinin histogramları.....	51
Şekil 4.3.	Rotanın bölümleri için bant gücü ortalamaları.....	53
Şekil 4.4.	İndeks değerleri histogramları.....	54
Şekil 4.5.	Rotanın bölümleri için indeks ortalamaları.....	56
Şekil 4.6.	Tüm katılımcılar için NASA-RTLX ve alt faktör skorlarının ortalamaları.....	58
Şekil 4.7.	Katılımcıların NASA-RTLX skoruna göre iş yükü seviyeleri.....	58
Şekil 4.8.	Sübjektif zihinsel zorluk skorlarının bölüm bazında ortalamaları.....	59
Şekil 4.9.	İndeks ortalamalarının katılımcıların cinsiyetlerine göre değişimi.....	62
Şekil 4.10.	İndeks ortalamalarının katılımcıların yaş gruplarına göre değişimi….....	63
Şekil 4.11.	İndeks ortalamalarının katılımcıların otomobil sürme tecrübesine göre değişimi.....	64
Şekil 4.12.	Veri Kümesi 1 için MI öznitelik önem sırası.....	68
Şekil 4.13.	Veri Kümesi 2 için MI öznitelik önem sırası.....	70

ÇİZELGELER DİZİNİ

		Sayfa
Çizelge 2.1.	Sürüş görevleri sırasında nörofizyolojik değişkenlerin değişimi.....	18
Çizelge 2.2.	Otomobil sürücülerinin bilişsel durumları hakkındaki çalışmalar…….....	21
Çizelge 2.3.	Otomobil sürücülerinin zihinsel iş yükü hakkındaki yapay zeka çalışmaları.....	27
Çizelge 3.1.	Deney rotasının bölümleri hakkında bilgiler….....	34
Çizelge 3.2.	Zihinsel iş yükü sınıflandırmasında kullanılan öznitelikler..	43
Çizelge 3.3.	Grid Arama ile araştırılan model parametreleri.....	46
Çizelge 4.1.	Alfa, teta, beta bant gücü tanımlayıcı istatistikleri.....	50
Çizelge 4.2.	Alfa, teta, beta bant gücü değerlerinin bölüm bazında tanımlayıcı istatistikleri.....	52
Çizelge 4.3.	İndeks değerleri tanımlayıcı istatistikleri.....	54
Çizelge 4.4.	Mental durum indekslerinin bölüm bazında tanımlayıcı istatistikleri.....	55
Çizelge 4.5.	NASA-RTLX ve alt faktörlere ait tanımlayıcı istatistikler...	57
Çizelge 4.6.	Sübjektif zihinsel zorluk skorlarına ait tanımlayıcı istatistikler…….....	59
Çizelge 4.7.	Trafik yoğunluğu ve yol tipine göre indeks ortalamaları.....	61
Çizelge 4.8.	Bant gücü ve indeks ortalamalarının cinsiyete göre değerlendirilmesi.....	61
Çizelge 4.9.	Bant gücü ve indeks ortalamalarının yaşa göre değerlendirilmesi.....	62
Çizelge 4.10.	Bant gücü ve indeks ortalamalarının otomobil sürme tecrübesine göre değerlendirilmesi.....	64
Çizelge 4.11.	Katılımcılar-arası sınıflandırma modelleri için optimal parametreler.....	65
Çizelge 4.12.	Veri Kümesi 1 için sınıflandırma performansları.....	66
Çizelge 4.13.	Veri Kümesi 1 için MI ve PCA ile seçilen öznitelik sayıları.....	67
Çizelge 4.14.	Veri Kümesi 2 için sınıflandırma performansları.....	68
Çizelge 4.15.	Katılımcılar-arası sınıflandırma modellerinin performansları arasındaki farkların tespiti için Mann-Whitney U Testi ile elde edilen p değerleri.....	69
Çizelge 4.16.	Veri Kümesi 2 için MI ve PCA ile seçilen öznitelik sayıları.....	70
Çizelge 4.17.	Katılımcı-bazında sınıflandırma performanslarının minimum, ortalama ve maksimum değerleri.....	72
Çizelge 4.18.	Katılımcı-bazında sınıflandırma modellerinin performansları arasındaki farkların tespiti için Mann-Whitney U Testi ile elde edilen p değerleri.....	73
Çizelge 4.19.	Katılımcı-bazında sınıflandırma modellerinde MI önem sırasına göre en önemli bulunan özniteliklerin dağılımı.....	74

1. GİRİŞ

Ergonomi; insan, makine ve malzemeden oluşan iş sistemlerini insan açısından inceleyen ve işin insana, insanın da işe uyumunu sağlayan bir bilim dalıdır. Ergonomi; özellikle çalışanlar ile iş ortamı arasındaki ilişkiyi inceler, iş ve işyeri düzenlemeleri yapar ve temelde insanın özellikleri, istekleri ve beklentilerine uygun iş düzenlemeleri gerçekleştirmeyi hedefler (Babalık, 2016). İnsan faktörleri ve ergonomi alanındaki araştırmacılar; hem fiziksel hem de bilişsel insan yeteneklerini ve sınırlamalarını incelemektedir ve bu bilgileri, insanların etkileşimde bulunmaları için daha güvenli, daha kullanışlı ve verimli çalışma ortamı tasarımları için kullanmaktadır (Dehais ve Ayaz, 2018).

Sinirbilim ve ergonominin bir noktada birleşerek oluşturduğu disiplinlerarası özel bir alan olan nöroergonomi, son yirmi yılda hızla gelişim göstermiştir. Nöroergonomi iş ortamında çalışan kişilerin beynini ve zihinsel davranışlarını inceleyen bir çalışma alanıdır (Parasuraman, 2003). Nöroergonomi, çalışanların zihinsel anlamda incelenmesi veya modellenmesi yoluyla çeşitli iş ortamlarındaki insan-makine sistemlerinin tasarımı ve değerlendirilmesi için kullanılır (Parasuraman, 2003; Parasuraman ve Rizzo, 2007). İnsan beyni ve işteki davranışlar ile ilgili çalışmaları kapsayan nöroergonomi, zihinsel iş yüklerini belirlemek ve performansı arttırmak amacıyla iş ortamlarının nasıl değiştirilebileceğini belirlemek üzere işle ilgili görevler ile beyin arasındaki ilişkiyi araştırmaktadır (James, 2012).

Nöroergonomi kapsamında bir işin veya görevin çalışan insan üzerinde nasıl bir etki yarattığını anlamak için gerçekleştirilen temel araştırmalardan biri mental iş yükünün belirlenmesidir. Bilişsel yük (cognitive load), bir görevin bilişsel talebi nedeniyle zihnin bilişsel kaynakları üzerinde oluşan yüktür. Bilişsel yük teorisi, eşzamanlı işlenmesi gereken bilginin miktarı ve etkileşimi ile ortaya çıkan, karmaşık bilişsel görevlerin öğrenilmesi ile ilgilenmekte ve bilişsel süreçler üzerinde durmaktadır (Sweller, 2011). İş yükü yalnızca gerçekleştirilen göreve bağlı değildir. Mental iş yükü (mental workload), kişinin ayırmaya istekli olduğu veya tahsis edebileceği kaynak miktarına da

bağlıdır bu nedenle hem bilişsel yük kavramına göre daha geniş hem de kişiye bağlı ve göreceli bir kavramdır.

Otomobil sürme işi görsel algı, mekânsal işleme ve motor tepkileri gerektiren oldukça karmaşık ve yaygın günlük hayat aktivitelerinden biridir ancak sinirsel temelleri hakkında çok az şey bilinmektedir. Nöroergonomi alanında, otomobil sürme işi için bütünleşik bir yaklaşım ele alınarak mevcut ergonomi modelleri sinirbilim verileriyle birleştirilmektedir (Navarro vd., 2018). Düz bir yolda, sabit hızla gerçekleştirilen bir sürüş görevinde, yüksek mental iş yükü objektif fizyolojik veya ikincil görev ölçümleri kullanılarak ölçülebilmektedir. Ölçülen iş yükü, sürücü performansının da bir göstergesi olarak görülmektedir. Ancak bir noktada sürücünün maruz kaldığı sürekli yüksek iş yükü, beklenmeyen bir yük artışına etkili bir şekilde tepki vermesini engelleyerek sürüş güvenliğini olumsuz etkileyebilmektedir (Parasuraman vd., 2008).

Trafik kazaları dünyada ölüm ve yaralanmaların önde gelen sebeplerinden biridir. Türkiye'de trafik kazalarında ölüm ve yaralanma oranları çoğu Avrupa ülkesine göre iki ila beş kat daha fazladır. Bu durum Türkiye'de yük ve yolcu taşımacılığının karayollarında yoğunlaşmasının açık bir sonucudur. Ülkedeki trafik kazalarının ve ölümlerin bir diğer önemli nedeni de araç sayısındaki hızlı artıştır (Akgüngör ve Doğan, 2009). 2023 yılının mayıs ayında trafiğe kayıtlı araç sayısı 27,5 milyona çıkmış ve önceki yıla göre %98,3 artış göstermiştir (Türkiye İstatistik Kurumu, 2023b).

Türkiye’de 2022 yılında gerçekleşen ölümlü ve/veya yaralanmalı trafik kazalarının nedenleri incelendiğinde; kusurların %86,8'inin sürücü, %9,5'inin yaya, %2,1'inin taşıt, %1,2'sinin yolcu ve %0,4'ünün yol kaynaklı olduğu görülmektedir (Türkiye İstatistik Kurumu, 2023a). Ölümlü ve/veya yaralanmalı trafik kazalarının sürücü kaynaklı sebepleri arasında alkollü araç kullanma, emniyet kemeri takmama, aşırı hız, dikkat dağınıklığı ve uykulu hal sayılabilir. Amerikan Ulusal Karayolu Trafik Güvenliği İdaresinin (NHTSA) istatistiklerinde 2021 yılında gerçekleşen motorlu araç kazalarının %13’ünün sürücünün dikkat dağınıklığı sebebiyle oluştuğu belirtilmiştir. Bu kazalarda 3522 kişi ölmüş, yaklaşık 362400 kişi yaralanmıştır (NHTSA, 2023).

NHTSA dikkat dağınıklığını "sürücünün dikkatini araçta yön bulma ve kritik olaylara tepki verme gibi temel görevlerden uzaklaştıran herhangi bir şey" olarak tanımlamaktadır. Başka bir deyişle, sürücünün gözlerini yoldan ayıran (görsel dikkat dağıtma), zihnini sürüş görevinden uzaklaştıran (bilişsel dikkat dağıtma) veya ellerini direksiyondan uzaklaştıran (manuel dikkat dağıtma) herhangi bir şey dikkat dağıtma olarak kabul edilmektedir (Venkatraman vd., 2021). Sürüş görevi sırasında trafik ve yol şartlarından kaynaklanan çeşitli sebeplerle sürücünün iş yükünün artması odaklanma problemi ve bilişsel dikkat dağınıklığına yol açabilmektedir. Dolayısıyla sürüş güvenliğini sağlayabilmek için sürücünün iş yükünün belirli bir seviyede kalması önemlidir.

Dünya Sağlık Örgütünün 2018 yılında yayınladığı Karayolu Güvenliğine İlişkin Küresel Durum Raporu'na göre, altmış dört ülkede dikkat dağınıklığıyla ilgili veriler polis raporları ve gözlemsel çalışmalar yoluyla rutin olarak toplanmaktadır (Dünya Sağlık Örgütü, 2018). Ancak gerçekleşen bir trafik kazası sonrası sürücünün durumunu raporlamak yerine, bir sürüş sırasında sürücünün mevcut durumunu takip edebilmek daha değerli olmaktadır. Bu sebeple sürücülerin mental durumunun objektif olarak görüntülenmesi ve takip edilmesi yol güvenliğinin sağlanması açısından büyük önem arz etmektedir. Ancak sürücülerin dikkat dağınıklığı, iş yükü veya yorgunluğunu gözlemlemek ve belirlemek kolay değildir. Bu noktada sürücüler üzerinde nöro-görüntüleme yöntemlerinin kullanılması yoluyla mental durumun sayısal ölçülerle ifade edilebilmesi fayda sağlayacaktır.

Son yirmi yılda özellikle nöro-görüntüleme alanında yaşanan gelişmeler nöroergonominin gelişimine olumlu katkı sağlamıştır. Geleneksel nöro-görüntülemede yüksek düzeyde kontrol altında olan ölçüm ortamlarından zamanla daha az kontrol altında olan gerçekçi durumlara doğru bir gelişim görülmüştür. Giyilebilir ve mobil nöro-görüntüleme teknikleriyle önceleri düşük doğruluklu simülatörler, daha sonra güvenilir simülatörler ve gerçekçi ayarlarda ölçüm yapmak mümkün olurken son yıllarda ulaşılan ultra-mobil nöro-görüntüleme aşamasında tamamen gerçek görevler sırasında ve gerçek ayarlarda insan beynini ölçümlemek mümkün hale gelmektedir.

Gelecekte ise nöro-görüntülemenin günlük hayatta gerçek zamanlı, sürekli ve çok yaygın olarak kullanılması beklenmektedir (Dehais ve Ayaz, 2018).

Sürücüler ve pilotlar üzerinde yapılan çalışmalar, nöro-görüntüleme yöntemlerindeki gelişimin en rahat görülebileceği alanlardır. Sürüş simülatörlerinde gerçekleştirilen deneyler vasıtasıyla yürütülen çalışmalar, zamanla daha gerçekçi ortamlarda yapılmaya başlanmıştır. Ancak gerçek ortamlarda yürütülen araştırmalarda bile genellikle gerçekçi bir senaryo söz konusudur.

Bu tez çalışmasının temel amacı, farklı trafik ve yol koşullarının otomobil sürücülerinin mental iş yükleri üzerindeki etkisinin bir nöroergonomi yaklaşımı ile araştırılmasıdır. Bu kapsamda trafik yoğunluğu, yol tipi ve kişisel faktörlerin sürücülerin mental iş yükü üzerindeki etkisi istatistiksel olarak incelenmiştir. Trafik yoğunluğu için düşük ve yüksek yoğunluk seviyeleri, yol tipi olarak şehir içi ara yol ve ana yol ve kişisel faktörler için de yaş, cinsiyet ve sürüş tecrübesi dikkate alınmıştır. Gerçek trafikte, toplam 39 gönüllü katılımcının şahsi otomobilleri ile yapılan sürüş deneylerinde kablosuz elektroensefalografi (EEG) ölçüm cihazı ile kaydedilen sinyaller istatistiksel olarak analiz edilmiştir. Sürücülerin EEG sinyalleri ile oluşturulan iki farklı veri kümesi üzerinde farklı öznitelik seçim algoritmaları ve makine öğrenmesi modelleri kullanılarak sürücülerin mental iş yükü sınıflandırılmış ve model performansları değerlendirilmiştir. Ayrıca mental iş yükü sınıflandırma modelleri katılımcı-bazında oluşturulan veri kümeleri üzerinde de uygulanmış, bireysel farklılıkları da dikkate alan katılımcı-bazında bir analiz gerçekleştirilmiştir.

Bu tez çalışmasının literatüre olan katkısı;

i. Tamamen gerçek trafik ortamındaki sürüş deneylerinde kaydedilen EEG verileri ile oluşturulan iki veri kümesinin sunulması,
ii. Trafik yoğunluğu, yol tipi ve kişisel faktörlerin sürücülerin mental iş yükleri üzerindeki etkisinin araştırılması,
iii. Çalışmaya özgü bir veri etiketleme yaklaşımı ile mental iş yükü seviyelerinin trafik ve yol koşullarına göre etiketlenmesi,
iv. Mental iş yükü sınıflandırmasında etkili olan özniteliklerin belirlenmesi,

v. Farklı makine öğrenmesi modellerinin oluşturulan iki farklı veri kümesi üzerindeki performanslarının değerlendirilmesi ve
vi. Katılımcılar-arası ve katılımcı-bazında uygulanan sınıflandırma modelleri vasıtasıyla bireysel farklılıkların sürücülerin mental iş yükünün sınıflandırılması üzerindeki etkisinin değerlendirilmesidir.

Sürücülerin beyin aktivitesinin incelenmesiyle bilişsel anlamda zorlayıcı olan sürüş koşulları belirlenebilecek, sürücü, araç ve yol güvenliğinin arttırılması konusunda fayda sağlanacaktır. Ayrıca gittikçe daha yaygın hale gelmekte olan otonom sürüşte, otonom sürüş seviyeleri sürücünün aracı kontrol etme oranına göre belirlenmektedir. Bu oran sürücünün anlık mental iş yüküne göre değiştirilebilir. Bu tez çalışmasında sürücülerin beyin aktivitesine dair elde edilen veri kümeleri ve analiz sonuçları, gelecekteki otonom sürüş çalışmaları için altyapı oluşturabilecektir.

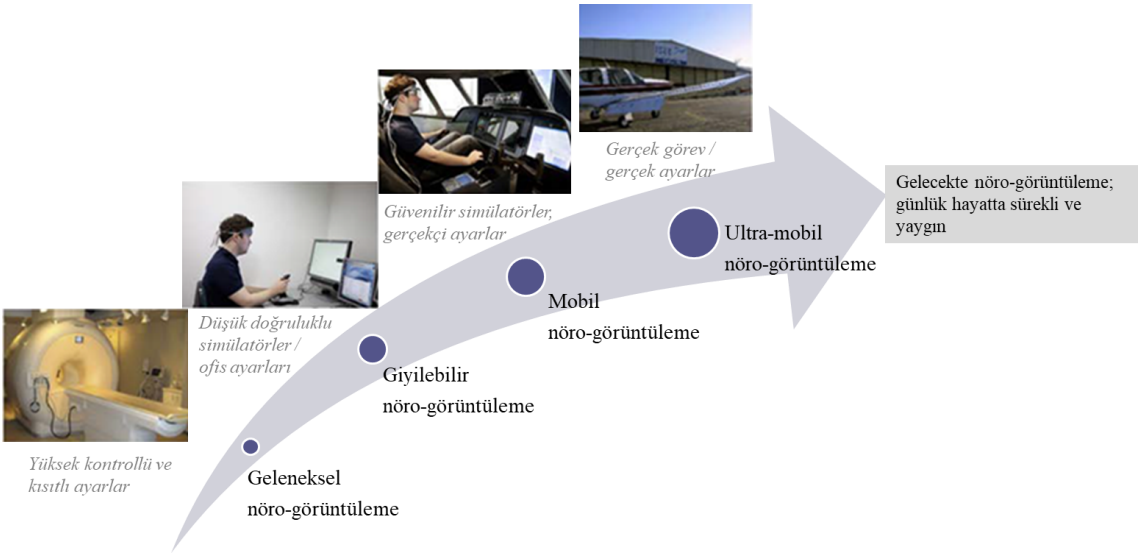
2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI

Bu bölümde ilk olarak nöroergonomi, nöro-görüntüleme yöntemleri ve mental iş yükü hakkında genel bilgi verilmiştir. Ardından otomobil sürücülerinin mental iş yüklerinin araştırılması kapsamında literatürde yer alan çalışmalardan bahsedilmiştir.

2.1. Nöroergonomi

Nöroergonomi kavramı ilk olarak Parasuraman (2003) tarafından işyerinde ve günlük hayat aktivitelerinde beyin ve davranışın incelenmesi şeklinde tanımlanmıştır. Profesör Raja Parasuraman nesnel ve zihni dikkate almayan "bilişsel sinirbilim" yaklaşımı ile öznel ve beyni dikkate almayan "ergonomi" yaklaşımını birleştirmeye karar vererek, nöroergonomi kavramını ortaya çıkarmıştır (Dehais ve Ayaz, 2018). Nöroergonomi, teknoloji, iş, eğlence, ulaşım, sağlık hizmetleri ve diğer ortamlarla ilişkili olarak zihinsel işlevlerin ve fiziksel performansın sinirsel temellerinin araştırılmasına odaklanmaktadır. Nöroergonominin iki temel hedefi, daha güvenli ve daha verimli çalışma için teknoloji ve çalışma ortamı tasarımında beyin fonksiyonu ve insan performansı hakkındaki bilgileri kullanmak ve insan performansının altında yatan beyin fonksiyonuna ilişkin anlayışı geliştirmektir (Parasuraman, 2003).

Nöroergonomi alanında araştırmacılar beyin aktivitesini doğrudan veya dolaylı olarak yansıtabilen fizyolojik ölçüm yöntemlerinden faydalanmaktadır. Çalışan insanın zihinsel performansı ile ilgili çeşitli konularda başta EEG ve fonksiyonel manyetik rezonans görüntüleme (fMRI) olmak üzere birçok farklı fizyolojik beyin görüntüleme, diğer bir deyişle nöro-görüntüleme yöntemi kullanılmaktadır. Bu yöntemler, herhangi bir gerçek görevi yerine getirirken beyinde aktif olan alanların ve aktif alanlar arasındaki korelasyonların incelenmesini sağlamaktadır (Posner, 2012). Nöro-görüntüleme tekniklerinde cihaz donanımı ve uygulama açısından son yıllarda meydana gelen hızlı teknolojik gelişmeler, nöroergonomi araştırmalarının gelişimine de yön vermiştir (Şekil 2.1).



Şekil 2.1. Nöroergonomi araştırmalarının gelişimi (Dehais ve Ayaz, 2018)

Başlıca nöro-görüntüleme yöntemleri aşağıda kısaca açıklanmıştır (James, 2012; Lew, 2013):

- *Elektroensefalografi (EEG):* Beynin ürettiği çok düşük voltajlı elektrik sinyallerinin saçlı deriye bağlanan elektrotlarla doğrudan kaydedilmesi tekniğidir. Beyinde üretilen anlamlı dalgaların ölçümünü sağlayarak beyin fonksiyonu hakkında yorum yapmaya olanak tanımaktadır. Beyindeki elektriksel aktivitedeki değişiklikleri milisaniye düzeyinde tespit edebildiğinden, çok yüksek zamansal çözünürlüğe sahiptir.
- *Olaya İlişkin Potansiyel (ERP):* Beynin belirli duyusal, motor ve bilişsel olaylara nöronlar bazında verdiği tepkiyi temsil eden ERP'ler, kişinin kafa derisinden EEG sinyallerinin kaydedilmesi ve belirli bir olaya bağlı EEG örneklemlerinin ortalamasının alınması yoluyla hesaplanmaktadır. N100, P300 gibi birçok ERP bileşeni mevcuttur. Örneğin karar verme süreci ile ilişkilendirilen P300 bileşeni, belirli bir olay ya da uyaranın meydana gelmesinden itibaren 250-500 ms arasında EEG dalgasında pozitif bir tepe noktası olarak oluşur (Fu ve Parasuraman, 2007).
- *Manyetoensefalografi (MEG):* Beyindeki aktivite sırasında oluşan manyetik alan değişikliklerinin takip edilerek işleyen bölgelerin tespit edilmesidir. Mekânsal çözünürlüğü oldukça yüksektir.

- *Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI):* Beynin belli bölgelerini aktif haldeyken görüntülemeyi amaçlayan bir tekniktir. Ölçüm sırasında kişiye görsel ya da işitsel uyaran verildiğinde, kişinin belirli beyin bölgelerinde kan akımı ve oksijenlenme artmaktadır. fMRI bu artışı ölçmeye duyarlı olduğundan bu şekilde beynin aktif olan bölgeleri görüntülenmiş olmaktadır. fMRI gibi metabolik ölçüler en iyi mekânsal çözünürlüğe sahiptir.
- *Fonksiyonel Yakın Kızılötesi Spektroskopi (fNIRS):* Beyindeki kan oksijenlenmesini ölçmek için kullanılan optik bir tekniktir. Spektrumun yakın kızılötesi kısmındaki ışığı (700-900 nm) kafatasından parlatarak ve kalan ışığın ne kadar azaldığını tespit ederek çalışır. Işığın ne kadar azaldığı kandaki oksijene ve dolayısıyla oradaki aktiviteye bağlı olduğundan fNIRS dolaylı bir beyin aktivitesi ölçümü sağlayabilmektedir.
- *Bilgisayarlı Tomografi (BT):* X ışınlarının diferansiyel emilimine dayanarak beynin resmini oluşturan bir tarama tekniğidir.
- *Pozitron Emisyon Tomografisi (PET):* Radyoaktif olarak işaretlenmiş bir molekülün vücuda verilmesi ve beyindeki kan akımı değişikliklerinin bu molekül aracılığıyla takip edilmesidir. Radyoaktif madde alımı, pahalı olması ve yavaş görüntüleme sebebiyle son yıllarda kullanımı azalmaktadır.

Direkt beyin aktivitesi ölçen yöntemlerin dışında, zihinsel süreçlerin etkilerinin dolaylı olarak ölçüldüğü fizyolojik ölçüm yöntemleri de bulunmaktadır. Bunların başında göz hareketleri, kalp atış frekansı (KAF), galvanik deri iletkenliği (GSR) ve kan basıncı gelmektedir (James, 2012; Lew, 2013):

- *Kalp Atış Frekansı (KAF):* Kalp kası aktivitesini yansıtan elektrik dalgalanmalarını tespit eden bir elektrokardiyogram kullanılarak ölçülür. Stres veya iş yükünü yansıtan bir gösterge olarak KAF değişkenliği, ortalama kalp atış hızının standart sapması olarak hesaplanmaktadır.
- *Galvanik Deri İletkenliği (GSR):* Deri iletkenliği veya galvanik deri tepkimesi olarak da bilinen GSR derideki ter bezlerinin durumunu ölçmektedir. Derinin elektrik direnci, ter bezlerinin durumuna göre değişiklik göstermektedir. Bazı

uyaranlar karşısında veya stres arttığında, terleme olmakta ve dolayısıyla deri iletkenliği artmaktadır.

- *Göz Hareketleri ve Göz Bebeği Büyüklüğü:* Elektrookülogram (EOG), kişinin göz kırpma hızını, göz kapanma süresini ve göz kırpma süresini ölçebilen elektrofizyolojik bir araçtır. Göz hareketleri ile ilgili göstergeler ve göz bebeği büyüklüğü değeri çoğunlukla kişilerin stres, uyku, yorgunluk ve mental durumlarını incelemek için kullanılmaktadır.
- *Kan Basıncı:* Beyindeki nöron hücrelerinin elektriksel aktivitesi, ilgili hücresel süreçlerin enerji talepleri ve beyindeki bölgesel kan akışı arasında yakın bir bağlantı mevcuttur. Herhangi bir zihinsel aktivite, beynin belirli bölgelerinde bir tepkiyle sonuçlandığında, o bölgedeki serebral metabolizma ve kan akışını değerlendirerek zihinsel iş yükünü ölçmek mümkündür.

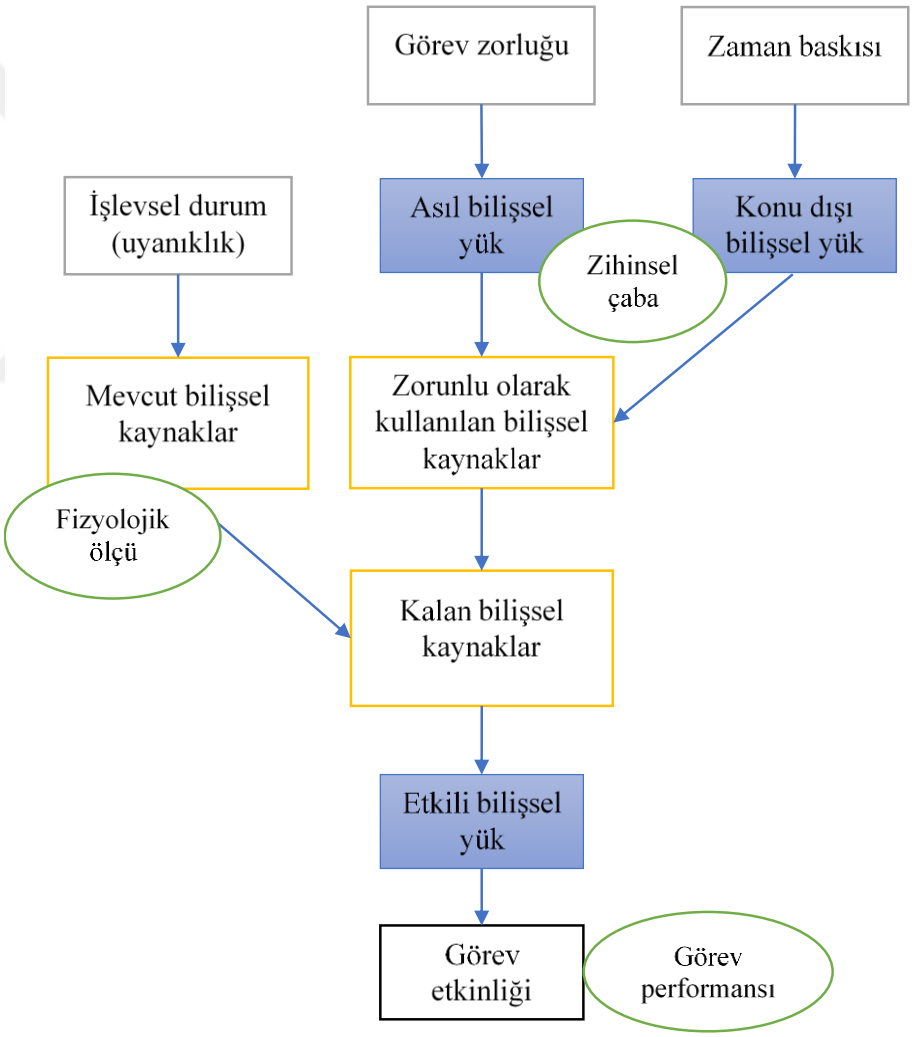
2.2. Mental İş Yükü

İnsanın bilgi işleme süreçlerinde sınırlı bir çalışma belleğine sahip olduğu düşünülmektedir. Dolayısıyla bilişsel yük, belirli bir zaman diliminde kişinin çalışma belleği tarafından kullanılan kısıtlı kaynaklar olarak tanımlanmaktadır. Sweller'ın Bilişsel Yük Teorisi'ne göre bilişsel yük üçe ayrılmaktadır:

- Asıl (intrinsic) yük,
- Konu dışı (extranous) yük ve
- Etkili (germane) yük (Sweller, 1988, 1994).

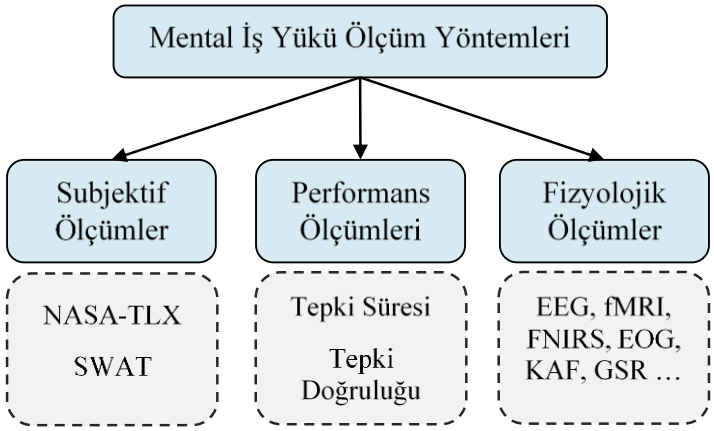
Bilişsel yük faktörleri ile bilişsel yük kategorileri arasındaki ilişkilerin grafiksel gösterimi Şekil 2.2'de görülmektedir. Asıl yük, öğrenme ve bilgi işleme sırasında çalışma belleğinde asıl yüklenmenin gerçekleştiği türdür. Konu dışı yük, çevreden kaynaklanan dışsal etkenler sonucunda çalışma belleğine gelen yüktür. Etkili yük ise zihinsel yapıların oluşması ve otomasyonu sağlayan süreçlerde ortaya çıkmaktadır (Paas vd., 2003a). Etkili yük, asıl bilişsel yükün üstesinden gelmek için gereken bilişsel kaynaklar olarak da tanımlanabilir (Antonenko vd., 2010).

Bilişsel yük ve mental iş yükü birbiriyle benzer kavramlar olmakla birlikte, anlamlarında küçük farklar söz konusudur. Bilişsel yük, bir görev esnasındaki algılama, bilgi işleme, dikkat, hafıza ve problem çözme gibi zihinsel faaliyet ve süreçleri kapsamaktadır. Mental iş yükü ise, bilişsel yük ile birlikte kişinin duygu durumu, kişisel motivasyonu, bireysel kaynakları ve görev talebi gibi farklı faktörleri de içeren daha geniş bir kavramdır. Mental iş yükü kişinin sınırlı kaynak kapasitesinin belirli bir zaman diliminde ya da belirli bir görevi yerine getirmek için çalışma belleği tarafından kullanılan kısmı olarak tanımlanmaktadır (O'Donnel & Eggemeier, 1986). Kısaca bir görevin zihinsel talebi olarak da ifade edilebilir (Miyake, 2001).



Şekil 2.2. Bilişsel yük faktörleri ile bilişsel yük kategorileri arasındaki ilişkiler (Galy vd., 2012)

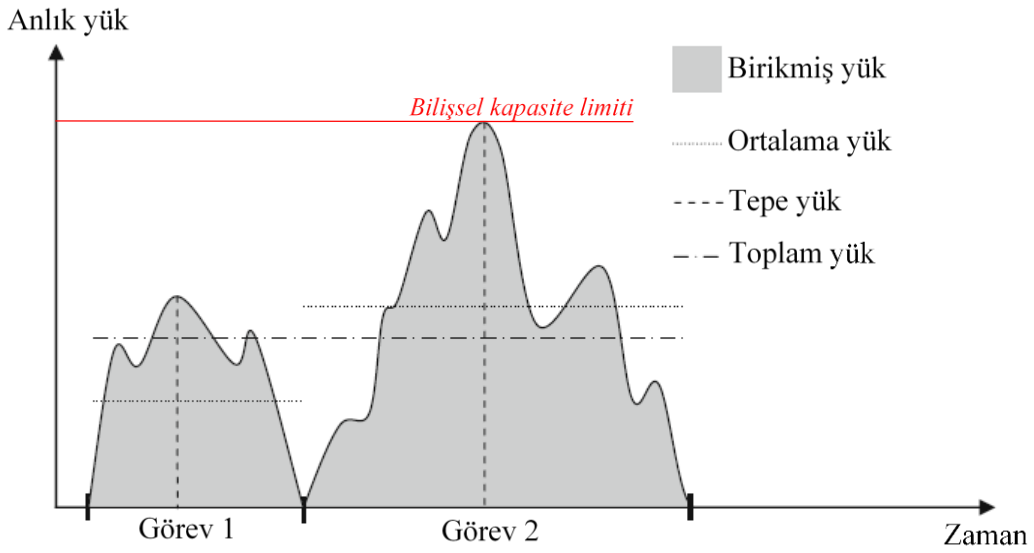
Mental iş yükü ölçüm yöntemleri subjektif ölçümler, performans ölçümleri ve fizyolojik ölçümler olarak sınıflandırılabilir (Galy vd., 2012). Subjektif ölçümlerden en yaygın kullanılan ikisi NASA-Görev Yükü İndeksi (NASA-TLX) ve Subjektif İş Yükü Değerlendirme Tekniği (SWAT)'dir. NASA-TLX, zihinsel talep, fiziksel talep, zamansal talep, performans, çaba ve kaygı/boşa çaba düzeyini araştıran altı alt faktörü içermektedir (Hart & Staveland, 1988). SWAT ise operatörün iş yükünü zaman, zihinsel çaba ve psikolojik stres yükü boyutlarıyla tanımlamaktadır (Reid & Nygren, 1988). Katılımcıların mental iş yükünü temsil eden performans ölçümleri genellikle tepki süresi ve tepki doğruluğu olarak kabul edilmektedir. Fizyolojik ölçümler ise bedensel süreçlerdeki değişiklikleri sürekli olarak ölçerek, mental yükün yüksek bir hassasiyetle ölçülmesine imkân vermektedir (Paas, 1992) (Şekil 2.3).



Şekil 2.3. Mental iş yükü ölçüm yöntemleri

Mental iş yükü farklı düzeylerde ölçülebilmektedir. Xie ve Salvendy (2000) bunları anlık yük, tepe (peak) yük, ortalama yük, birikmiş yük ve toplam yük olarak ayırmıştır (Şekil 2.4). Anlık yük, bir görevin veya görev dizisinin gerçekleştirilmesinin başından sonuna kadar her an dalgalanan bilişsel yükün hareketini yansıtmaktadır. Bilişsel yükü ölçmede temel düzeyin anlık yük olduğu söylenebilir, çünkü diğer düzeyler de anlık yükten türetilmektedir. Tepe yük, görevin gerçekleştirilmesi sırasında oluşan anlık yükün maksimum değeridir. Birikmiş yük, görev sırasında deneyimlenen toplam yük miktarıdır; anlık yük eğrisinin altındaki alan olarak düşünülebilir. Ortalama yük, birim zaman başına birikmiş yüke eşit olan anlık yüklerin ortalama değeridir. Toplam yük ise

tüm çalışma prosedürüne dayalı deneyimlenen yüktür; ancak birikmiş ya da ortalama yüke eşit değildir (Xie ve Salvendy, 2000). Kişinin zihinsel çaba algısını toplam yük değeri temsil etmektedir. Mental iş yükünü ölçmek üzere kullanılan subjektif ölçek yöntemleri, bu düzeydeki yükü ölçmektedir (Antonenko vd., 2010).



Şekil 2.4. Zamana göre mental iş yükünün farklı düzeyleri (Antonenko vd., 2010)

Subjektif ölçek yöntemleri genellikle zihinsel çaba miktarını sorgulamaktadır. Zihinsel çaba, görevin gerektirdiği talepleri karşılamak için tahsis edilen bilişsel kapasiteyi ifade eden bilişsel yük yönü olarak tanımlanabilir; dolayısıyla gerçek bilişsel yükü yansıttığı düşünülebilir (Paas vd., 2003b). Ölçek yöntemi görevden hemen sonra uygulandığında birikmiş yükü, bir dizi görevden sonra uygulandığında ise toplam yükü temsil edebilir. Bu sebeple subjektif ölçek yöntemleri anlık yükün zaman içindeki dalgalanmaları hakkında fikir vermemektedir. Anlık yükün takip edilebilmesi için fizyolojik nöro-görüntüleme yöntemlerinin kullanılması daha doğru olacaktır.

EEG tabanlı zihinsel iş yükü göstergeleri arasında ham EEG sinyalleri (Almogbel vd., 2018), P300 genliği (Causse vd., 2015), bant güçleri (teta, alfa vb.) ve bant güçlerinin çeşitli kombinasyonları ile hesaplanan indeks değerleri (Frontal Teta/Parietal Alfa vb.) sayılabilir. Bunlar arasında yükü en iyi ifade edenler P300 genliği ve Frontal Teta/Parietal Alfa oranı olarak bulunmuştur (Holm vd., 2009).

Bu konuda kullanılan göstergeler arasında zihinsel iş yükü ile ilişkilendirilen P300 gibi olaya ilişkin potansiyellere ek olarak EEG tabanlı beyin-bilgisayar ara yüzlerinde kullanılan Durağan Hal Görsel Uyarılmış Potansiyel (SSVEP) (Muller-Putz vd., 2006) ve motor imgeleme ile üretilen Olaya İlişkin Senkronizasyon/Desenkronizasyon (ERD/ERS) (Pfurtscheller ve da Silva, 1999) aktiviteleri sayılabilir. Zihinsel iş yükü arttıkça beynin kaynakları daha fazla devreye girerek uyarılmış potansiyel yanıtlarını etkileyebilir. Zihinsel iş yükünün değişmesi SSVEP'in genliğinde ve sıklığında değişikliklere yol açabilir. SSVEP bilişsel yük araştırmacıları için ilgi çekici bir unsur haline gelmiştir (Ozkan ve Kahya, 2014). Bu tez çalışmasında görsel uyaranlara odaklanmak yerine gerçek sürüş görevi için bütüncül bir zihinsel iş yükü araştırması yapmak amaçlandığından olaya ilişkin ve uyarılmış potansiyeller kullanılmamıştır.

Bu tez çalışmasında kullanılan Frontal Teta/Parietal Alfa (Holm vd., 2009) ve Orta Frontal Teta (Yamada, 1998), çeşitli görevler sırasındaki zihinsel iş yükünü gösterdiği kanıtlanmış indekslerdir. Sürücülerin EEG sinyallerini analiz eden çalışmaların çoğu teta, alfa ve beta bant güçlerine odaklanmaktadır (Borghini vd., 2014). Beta bandının çalışma belleğini kontrol eden bir mekanizma görevi gördüğü ve düşünceler üzerinde kontrol sağlayan beyin fonksiyonu olduğu söylenmektedir (Lundqvist vd., 2018). Aynı zamanda beta bant gücünün de zihinsel iş yükü ile ilişkili olduğu öne sürülmektedir (Kumar ve Kumar, 2016; Guo vd., 2021). Dolayısıyla bu tez çalışmasında incelenmek üzere beta bant gücünü de içeren ve literatürde zihinsel yorgunluğun bir göstergesi olarak bilinen (Alfa+Teta)/Beta oranı (Jap vd., 2009; Wang ve Mu, 2021) da incelenmek üzere seçilmiştir.

Farklı zihinsel iş yükü seviyelerinde EEG aktivitesinde önemli farklılıklar oluşmaktadır. Teta ve alfa dalgaları bu farklılıklara daha duyarlıdır (Liang vd., 2018). Teta bant gücü dikkat taleplerini, görev zorluğunu ve bilişsel yükü yansıtır. Rahatlama durumuna kıyasla çalışma belleği görevi sırasında mental performans arttıkça alfa bant gücü azalır ve teta bant gücü artar. Özellikle gözler kapalı dinlenme durumunda alfa dalgalarında artış gözlemlenir (Klimesch, 1999). Farklı EEG bantları, farklı beyin bölgelerinde baskın olarak etkilidir. Frontal bölgedeki teta bandı ve parietal bölgedeki alfa bandı zihinsel iş yükünün göstergesi gibi görünmektedir (Aricò vd., 2016). Artan iş yükü ile

frontal, parietal ve oksipital tetada artış ve oksipital alfada azalma oluşmaktadır (Kutafina vd., 2021). Beyin aktivitesi ve bilişsel görevlerin zorluğu sebebiyle kişilerde oluşan bilişsel yükün artışı parietal alfa gücündeki azalma ile tespit edilebilmektedir (Zammouri vd., 2017). Orta frontal bölgede ise teta bant gücü, gerçekleştirilen görevin zorlaşması ve çalışma belleği yükünün artmasıyla birlikte artmaktadır (Gevins ve Smith, 2003). Ayrıca motor kontrol ve yüksek uyarılma söz konusu ise beta dalga gücü artmaktadır (García-Monge vd., 2020).

Literatürde çeşitli görevler sırasında oluşan mental iş yükünü farklı yönlerden ele alan çalışmalar mevcuttur. Bu çalışmaların genel amacı daha güvenli ve daha verimli çalışma ortamlarının tasarlanmasıdır. Anlık iş yükünün ölçülebilmesi ve gelişmiş cihazlar açısından birçok çalışmada EEG yöntemi tek başına veya diğer yöntemlerle birlikte kullanılmaktadır.

Çeşitli bilişsel görevler sırasında ölçülen EEG sinyallerinden hesaplanan işe katılım (engagement) ve mental iş yükü göstergelerinin uygunluğunun araştırıldığı çalışmada, katılımcıların EEG sinyalleri ile birlikte mental çaba için sübjektif derecelendirme puanı kaydedilmiştir. Zihinsel aritmetik görevleri ve sayı dizisi testleri gibi beş görevden oluşan bir dizi deney gerçekleştirilmiş, görevlerde zorluk seviyesi arttıkça iş yükünün doğrusal olarak arttığı görülmüştür. Ayrıca EEG göstergelerinin hem nesnel hem de öznel performans değerleri ile korelasyon gösterdiği ve iş yükünün problem çözme ve analitik akıl yürütme sırasında çalışma belleği yükünün artmasıyla arttığı tespit edilmiştir (Berka vd., 2007).

Giyilebilir cihazlar ile mental iş yükünün ölçülmesi konusunda EEG bağlantılı özelliklerin kullanılması önerilmektedir. Giyilebilir teknolojiler, kullanım kolaylığı, konfor ve taşınabilirlik sağlarken, sinyal okuma kalitesinin düşük olması (örneğin kuru elektrotlar nedeniyle) ve kayıt altına aldığı beyin bölgesi sayısının nispeten az olması gibi bazı dezavantajlara da sahiptir. Bunların üstesinden gelebilmek için, giyilebilir EEG cihazından faz ve genlik değerlerini birleştiren özelliklerin hesaplanması ve kullanılması önerilmiştir (Drouin-Picaro vd., 2017).

Geçtiğimiz on yılda, çeşitli görevlerde oluşan mental iş yükünün sınıflandırılması için başta EEG olmak üzere diğer nöro-görüntüleme yöntemleri ve sübjektif değerlendirme yöntemlerinden elde edilen veriyi kullanarak denetimli ve denetimsiz makine öğrenmesi modellerinden faydalanıldığı görülmektedir.

Bireyler belirli bir zihinsel görev için farklı seviyelerde bilişsel yük sergileyebilirler. Denetimli öğrenme algoritmaları tarafından farklı mental iş yükü seviyeleri için oluşturulan bir modelin, normalizasyon sorunu nedeniyle tüm bireyler için kullanılamayacağının belirtildiği bir çalışmada, Stroop testi, mantıksal akıl yürütme ve ekran klavyesini kullanarak yazı yazma görevleri için denetimsiz bir algoritma olan Bulanık C-Ortalamalar önerilmektedir. Bileşen-bazlı Bulanık C-Ortalamalar modelinin karşılaştırılabilir olduğu ve bazen denetimli modellere (örneğin SVM) göre daha iyi performans gösterdiği belirtilmektedir (Das vd., 2013).

Daha önce söz edildiği gibi mental iş yükünün sınıflandırılması için EEG yöntemi ile birlikte diğer fizyolojik ölçümler ve sübjektif anketler birlikte kullanılmıştır. Bir n-geri görevi sırasında EEG, fNIRS, KAF ve solunum verilerinin ölçüldüğü ve LDA ile mental iş yükü sınıflandırması için kullanıldığı çalışmada, EEG ve fNIRS verilerinin birlikte en iyi sonucu verdiği görülmüştür. Ancak fizyolojik verilerin de dahil edilmesi sınıflandırma performansını etkilememektedir (Liu vd., 2017). Benzer bir n-geri görevinde EEG ve NASA-TLX verisi kaydedilmiş, mental iş yükünü sınıflandırmak için RO tabanlı sınıflandırma modelleri ile mental iş yükü sınıflandırılmıştır. Bu konuyla ilgili çalışmalarda fazla kullanılmamış olan GBM modeli yüksek performans göstermiştir. Bu konuda en etkili bağımsız değişkenlerin ön-frontal ve frontal teta, ön-frontal yüsek beta, oksipital, parietal ve temporal gama ve oksipital alfa aktiviteleri olduğu belirlenmiştir. Ayrıca NASA-TLX skoru ile bazı EEG parametrelerinin ilişkili olduğu tespit edilmiştir. Algılanan zihinsel iş yükü arttıkça frontal teta, frontal gama, parietal gama ve oksipital gama güçleri artmaktadır (Harputlu Aksu & Çakıt, 2022).

Makine öğrenmesi modelleri gürültü sinyallerinin giderilmesi ve öznitelik çıkarımının manuel olarak yapılmasını gerektirdiğinden, mental iş yükü sınıflandırması için derin öğrenme modelleri de kullanılmaya başlanmıştır. Derin öğrenme modellerinde de

yaygın olarak kullanılan girdi verisi EEG sinyalleridir. EEG sinyallerinden mental iş yükünün sınıflandırılması için derin öğrenme modellerinden faydalanan ilk çalışmalardan birinde, bir metin okuma görevi sırasında kaydedilen EEG sinyallerinden öznitelik çıkarımı için iki farklı derin öğrenme modeli kullanılmıştır. Otokodlayıcı ve LSTM tabanlı öznitelik çıkarımı modelleri, ardından MLP tabanlı sınıflandırma modeli uygulanmış ve SVM, kNN ve LDA gibi geleneksel makine öğrenmesi sınıflandırıcılarından daha iyi performans gösterdiği görülmüştür (Saha vd., 2018). Sınıflandırma için gereken en iyi öznitelikleri otomatik olarak çıkaran bir derin öğrenme modeli bilinen diğer modellerle kıyaslandığında, basit bir 12 katmanlı 1-boyutlu CNN yapısının aritmetik işlemler sırasında kaydedilen EEG verilerinden oluşan veri kümesi üzerinde en iyi performansı sağladığı tespit edilmiştir (Diwakar vd., 2020). Güncel bir çalışmada ise bir n-geri görevindeki EEG verilerinden hesaplanan fonksiyonel bağlantı öznitelikleri kullanılarak üç derin öğrenme sınıflandırıcısı geliştirilmiştir. Üç bilişsel yük seviyesi barındıran CNN, LSTM ve evrişimli LSTM tabanlı katılımcıya özel (subject-specific) sınıflandırıcı modelleri karşılaştırıldığında, en yüksek sınıflandırma doğruluğuna evrişimli LSTM modelinin ulaştığı tespit edilmiştir (Gupta vd., 2021).

2.3. Otomobil Sürücülerinin Mental İş Yükü

Nöroergonominin ilgilendiği ortam ve görevler çok sayıda ve çeşitli olmakla birlikte, örnek olarak evde veya işyerinde bilgisayarlarla ve diğer farklı makinelerle çalışma, tüketici ürünlerini kullanma ve uçak, otomobil, tren gibi araçları kullanma işleri sayılabilir (Parasuraman, 2003). Otomobil sürme işi genellikle çoklu bilişsel süreçlerin yürütüldüğü bir iş olduğundan, otomobil sürüşündeki faktörlerin ve güvenlik önlemlerinin incelenmesi nöroergonominin uygulanabileceği önemli bir temsili alan olarak görülmektedir (Lees vd., 2010).

Günlük hayatta otomobil kullanma işi birçok kişinin yaptığı ve çok sık karşılaşılan bir iştir. Otomobil sürücülerinin fiziksel konforu, henüz otomobiller tasarım aşamasındayken düşünülmekte ve günümüzde buna yönelik araçlar tasarlanmaktadır. Ancak otomobil kullanma işi zihinsel olarak ele alındığında, karmaşık bir işlem olduğu görülmektedir. Çünkü sürücünün eş zamanlı olarak birden çok gösterge verisi ve

uyarana maruz kaldığı ve güvenli bir sürüşü devam ettirebilmek için sürekli dikkatli ve odaklanmış halde, gerekli tepkileri vermeye hazır olması gerektiği bir iştir. Sürücüler gerçek trafik ortamında otomobil kullanırken, devamlı olarak çevreden gelen uyaranlara karşı açık olmalı, doğru tepkileri zamanında verebilmeli, dikkatsiz davranmamalı, aynı zamanda sürüşün gerektirdiği manuel işlemleri (gaza/frene basma, vites değiştirme, şerit takip etme, sinyal verme vs.) yapıyor olmalıdır. Bu işlemler göz önüne alındığında sürücülerin veri işleme, odaklanma, uyanıklık ve karar verme gibi karmaşık zihinsel süreçlerden geçtiği görülmektedir. Trafik yoğunluğu ve yol koşulları gibi faktörler hem sürücüleri hem de sürüş performanslarını etkilemektedir. Otomobil sürüşü sırasında kişilerin zihinsel durumları sürüş güvenliği ve sürüş performansı üzerinde etkili olmaktadır. Bu sebeple özellikle farklı trafik ve yol şartlarında sürücülerin bilişsel durumlarının incelenmesi gerekmektedir. Bilişsel yükün sayısal olarak ortaya konabilmesi de önemli olacaktır.

Literatürde sürücüler üzerinde uyanıklık, uyku hali, rahatlık, yorgunluk, dikkat, durum farkındalığı, zaman baskısı ve çoklu görev (multi-tasking) gibi kavramlar incelenmiştir. Zihinsel yük veya zihinsel yorgunluk bu parametreler ile değerlendirilmektedir. Örneğin, zihinsel yük arttığında durum farkındalığı azalmakta, bu da işlem performansında düşüşe sebep olmaktadır (Borghini vd., 2014). İncelemelerde genellikle anket gibi sübjektif yöntemler ve nicel veri toplamaya imkân sağlayan fizyolojik yöntemler kullanılmaktadır. Katılımcı gruplarını genellikle genç yaşta üniversite öğrencileri oluştururken, bazı çalışmalarda yaşlı sürücüler üzerinde de deneyler yapılarak yaş ve tecrübe faktörü incelenmiştir.

Çizelge 2.1'de EEG dalgaları ve diğer bazı nörofizyolojik değişkenler ile farklı zihinsel faktörler arasındaki ilişkiler özetlenmiştir (Borghini vd., 2014). Tabloda her bir hücredeki + ve – işaretleri ilgili faktörde dinlenme haline göre artış (+) veya azalış (-) olduğunu, beyin bölgesi ifadeleri ise bu artış veya azalışların beynin özellikle hangi bölgelerinde belirgin olduğunu ifade etmektedir.

EEG ve EKG kullanılarak, mental yorgunluğun değerlendirildiği bir çalışmada, uzun bir sürüş görevi öncesi ve sonrası ölçümler yapılarak yorgunluk ve dikkat durumlarında

oluşan fark incelenmiştir. Sürüş görevi sonrasında alfa ve teta bant güçlerinin arttığı, beta bant gücünün ve P300 genliğinin azaldığı, bunun da zihinsel yorgunluğun oluşmasıyla uyarılma ve dikkat seviyesinin azalmasını gösterdiği belirtilmiştir (Zhao vd., 2012). EEG, KAF, göz takibi ve anket verileri kullanılarak, simülasyon ortamında otomobil sürerken zihinsel yorgunluk ve uyku halinin incelenmesi sonucunda EEG tabanlı bir iş yükü indeksi oluşturulmuştur. Oluşturulan indeks ile zor sürüş koşullarında teta bandındaki EEG güç spektrumlarının prefrontal bölgede arttığı ve alfa bandındaki EEG güç spektrumlarının parietal bölgede eşzamanlı olarak azaldığını tespit edilmiştir (Borghini vd., 2012).

Çizelge 2.1. Sürüş görevleri sırasında nörofizyolojik değişkenlerin değişimi (Borghini vd., 2014)

	Delta	**Teta**	**Alfa**	**Beta**	**EOG (göz kırpma hızı)**	**EOG (göz kırpma süresi)**	**KAF**
Dikkatli olma hali -		+	+				
Uyanıklık +				+			
Rahatlık +			+				
Uyku hali +			+				
Görev talebi +		Orta frontal, Parietal +	Frontal, Merkezi, Parietal -		-	-	+
Yorgunluk +	+	Orta frontal, Parietal +	Frontal, Oksipital +	Parietal -	-	-	+
Odaklanmış dikkat +		Orta frontal +					
Zaman baskısı +		Orta frontal, Merkezi +					
Sürekli dikkat ve çoklu görev +		+	-				
Sürüş performansı doğruluğu +		+	+				
Uyanıklıktan mental yorgunluğa ve uyku haline geçiş	+	Orta frontal, Parietal +	Frontal, Oksipital, Temporal +	Parietal -	+	+	-

Zihinsel çaba ve sürüş performansı arasındaki ilişkiyi analiz eden bir çalışmada, KAF ölçümleri ve sübjektif anket verileri alınmıştır. Zihinsel çabayı değiştirmek için yalnızca sürüş, iki bilişsel görevi çözerken sürüş ve sözel-görsel bilmeceler çözerken sürüş

olmak üzere üç deneysel koşul tasarlanmıştır. Ancak KAF değişkenliği zihinsel çabayı yansıtacak kadar hassas bulunmamıştır (Gabaude vd., 2012).

Sürücünün bilişsel durumunun objektif verilere göre otomatik olarak belirlendiği sistemlerin, sürüş güvenliği ve daha az bilişsel yüklenme için kullanılması faydalı olmaktadır. Örneğin kısmi otonom araçlarda sürücünün bilişsel durumunun belirlenip aracın kontrolünün sürücüye ne zaman güvenli şekilde aktarılabileceğinin belirlenmesi bu sistemlerle mümkün olmaktadır (Sibi vd., 2016).

Ahn vd. (2016) çalışmalarında uyku eksikliğinin sürücülerin mental yorgunluğu üzerindeki etkisini EEG, EKG ve fNIRS verilerini ölçerek ve spektral güç yoğunluğunu hesaplayarak belirlemişlerdir. Uykusuzluk halinde, alfa bandının gücü sağ merkez-parietal bölge için daha yüksek, beta bandının gücü ise ön-merkez bölge için daha düşük bulunduğundan sürüş için riskli olabilecek bir uyarılma eksikliği olduğu tespit edilmiştir. Yorgunluğun sürüş performansına etkisini EEG, göz takibi ve anket verileri ile inceleyen Morales vd. (2017), simülasyon ortamında iki saatlik bir sürüş görevi süresince hızın doğrusal olarak azaldığını ve hızlanma süresinin arttığını, bunun da yorgunluğu açık şekilde ifade ettiğini belirtmişlerdir. Sürüşün başında delta bant gücünün arttığı, daha sonra azalmaya başladığı görülmüştür. Beta bant gücü ise sürüş boyunca doğrusal olarak artmıştır.

Otomobil içerisinde sürüş görevleri haricinde yapılan diğer faaliyetlerin dikkat dağınıklığına sebep olduğu düşünülmektedir. Dikkat dağınıklığına sebep olan bu uyaranların, bilişsel yüke etkisi EEG ve anket yöntemleri ile incelenmiştir. NASA-TLX cevapları ve P300 genliklerine göre; radyo veya sesli kitap dinleme gibi araç içi faaliyetlerin düşük düzeyde, araçtaki bir yolcuyla veya cep telefonunda konuşma faaliyetinin orta düzeyde, konuşmadan bir e-posta veya mesaj okuyup yazmanın ise yüksek düzeyde bilişsel iş yükü içerdiği bulunmuştur (Strayer vd., 2015). Çoklu görevler ve dikkat dağınıklığının olduğu bir sürüş sırasında, beynin frontal bölgesinde artan teta dalgaları ve parietal ve oksipital bölgelerde azalmış alfa dalgaları da bu tip görevleri yerine getirirken bilişsel talepleri ve dikkat gerektiren durumları yansıtmaktadır (Y. K. Wang vd., 2018).

Geliştirilen bir EEG tabanlı zihinsel iş yükü indeksinde, gerçek sürüş koşullarında farklı trafik ve yol şartlarının etkisinin değerlendirilmesi amaçlanmıştır. Ölçülen verilerin sınıflandırılmasında LDA'nın özel bir hali kullanılmış, trafik yoğunluğunun artması ve otomobilin önüne yaya çıkması gibi durumlarda bilişsel yükün arttığı görülmüştür (Di Flumeri vd., 2018).

Yaşlı ve hasta katılımcılar üzerinde yapılan bir çalışmada ise EEG verisinden sürüş performansının tahmin edilmesi amaçlanmıştır. Hem gerçek yol hem de simülasyon ortamında yapılan deneylerde, ERP'den P200 bileşeninin genliğinin artması kötü bir sürüş performansı ile ilişkili bulunmuştur. Ayrıca performansı düşük olan sürücülerde daha yüksek alfa bant gücü oluştuğu görülmüştür (Rupp vd., 2019). Zihinsel talebin eş zamanlı gerçekleştirilmesi gereken işitsel, görsel ve takip görevlerinin sayısı ile ifade edildiği bir mental iş yükü incelemesine göre, N1 ve P3 ERP bileşenleri de zihinsel talepteki ve dolayısıyla mental iş yükündeki artışları tespit edebilen etkin ölçülerdir (Solís-Marcos & Kircher, 2019).

Sürüş sırasında dikkat dağıtıcı uyaranların olduğu durumlarda sürücünün dikkat dağınıklığının EEG verilerinden belirlenmesi için makine öğrenmesi yöntemleri kullanılmaktadır (Bajwa vd., 2019). Genel olarak çeşitli yapay sinir ağları bilişsel iş yükünü doğru bir şekilde sınıflandırabilmektedir (Baldwin ve Penaranda, 2012). EEG verisinden gürültü faktörleri temizlendikten sonra, riskli bilişsel yük seviyelerinin tanımlanması için makine öğrenmesi yöntemleri bu veri üzerinden eğitilebilmektedir. Örneğin, uyku hali ve yorgunluk gibi uyarılmanın az olduğu riskli durumlar güvensiz sürüş performansı ile ilişkilendirilmektedir. Modelin eğitilmesi aşamasında, farklı nörofizyolojik yöntemlerle alınan çok yönlü özellikler aynı anda kullanılmalıdır. Test aşamasında ise model uyanıklık durumlarının veya bilişsel yük seviyelerinin doğru sınıflandırılması açısından kontrol edilmektedir (Lohani vd., 2019).

Sürücülerin zihinsel iş yükünün ve orta yaşlı sürücülerin sürüş performanslarının incelendiği bir çalışmada, NASA-TLX, EEG ve performans ölçümleri birlikte kullanılmıştır. FZ, PZ, O1, O2, P3, and P4 kanallarından ölçüm alınmış, teta, alfa ve beta bant güçleri hesaplanmıştır. Frontal bölge kanallarındaki teta ve oksipital bölge

kanallarındaki alfa bant güçlerinin şehir içi yolda (çok karmaşık durum) daha düşük olduğu görülmüştür (Abd Rahman vd., 2020).

Araç otomasyon sistemlerinin gelişmesiyle bu sistemlerin sürücülerin zihinsel göstergeleri üzerindeki etkisi de incelenmeye başlanmıştır. Gerçek sürüş sırasında kısmi araç içi otomasyon sisteminin sürücünün zihinsel durumuna etkisini belirleyebilmek için mental iş yükü ve görsel etkileşim incelenmiştir. Yetmiş bir katılımcının EEG sinyalleri ile hesaplanan frontal teta ve parietal alfa bant güçlerinin analiz edilmesiyle, kısmi araç içi otomasyonu ile sürüş ve manuel sürüş arasında mental iş yükü ve görsel etkileşim açısından herhangi bir değişiklik olmadığı ortaya çıkarılmıştır (McDonnell vd., 2023).

Otomobil sürücülerinin bilişsel durumları hakkında EEG, EOG, fNIRS, KAF, anket vb. ölçüm yöntemlerini kullanarak çeşitli faktörlerin incelendiği, önceki paragraflarda bahsedilen çalışmalar Çizelge 2.2'de özetlenmiştir.

Çizelge 2.2. Otomobil sürücülerinin bilişsel durumları hakkındaki çalışmalar

Kaynak	Amaç	Veri Toplama Yöntemi	Analiz Parametresi	Analiz Yöntemi	Katılımcı Sayısı	Deney Ortamı
(Borghini vd., 2012)	Yorgunluk ve uyku halini gösteren indeks oluşturulması	EEG, KAF, göz takibi, anket	Güç spektrum yoğunluğu	Frontal teta / Parietal alfa oranı	-	Simülasyon
(Gabaude vd., 2012)	Zihinsel çaba ve sürüş performansı arasındaki ilişkinin incelenmesi	KAF, anket	Kalp atış frekansı değişkenliği	ANOVA	21	Simülasyon
(Zhao vd., 2012)	Zihinsel yorgunluğun sürüş öncesi ve sonrası için karşılaştırılması	EEG, EKG	Güç spektrum yoğunluğu, P300bileşeni	Bağımlı örneklem t-testi	13	Simülasyon
(Strayer vd., 2015)	Farklı aktivitelerin dikkat dağınıklığı ve bilişsel yüke etkisinin incelenmesi	EEG, anket	ERP, P300 bileşeni	ANOVA	38	Gerçek ve simülasyon

Çizelge 2.2. Otomobil sürücülerinin bilişsel durumları hakkındaki çalışmalar (devam)

Kaynak	Amaç	Veri Toplama Yöntemi	Analiz Parametresi	Analiz Yöntemi	Katılımcı Sayısı	Deney Ortamı
(Ahn vd., 2016)	Uyku eksikliğinin yorgunluğa etkisinin araştırılması	EEG, EKG, fNIRS	Güç spektrum yoğunluğu	LDA	11	Simülasyon
(Sibi vd., 2016)	Çoklu görevlerin bilişsel yüke etkisinin araştırılması	fNIRS	Prefrontal korteks aktivasyonu	Reaksiyon süresi karşılaştırma	14	Simülasyon
(Morales vd., 2017)	Yorgunluğun sürüş performansına etkisinin incelenmesi	EEG, Göz takibi, anket	Güç spektrum yoğunluğu	ANOVA	15	Simülasyon
(Di Flumeri vd., 2018)	Trafik ve yol koşullarının bilişsel yüke etkisinin gösterilmesi	EEG, göz takibi, anket	Güç spektrum yoğunluğu	LDA	20	Gerçek
(Wang vd., 2018)	Dikkat dağınıklığı olan sürüş sırasında alfa ve teta dalgalarının incelenmesi	EEG	Güç spektrum yoğunluğu	Wilcoxon testi	14	Simülasyon
(Bajwa vd., 2019)	Dikkat dağınıklığının belirlenmesi	EEG	Güç spektrum yoğunluğu	Bayes ağı, MLP	15	Gerçek
(Rupp vd., 2019)	EEG verisinden sürüş performansı tahmini	EEG	ERP, P200 bileşeni	LDA	98	Gerçek ve simülasyon
(Solís-Marcos ve Kircher, 2019)	Araç içi bilgi sistemi kullanılırken mental iş yükünün incelenmesi	EEG, göz takibi, anket	ERP, N1 ve P3 bileşenleri	ANOVA	17	Simülasyon
(Abd Rahman vd., 2020)	Orta yaşlı sürücülerin mental iş yükü ve sürüş performansının incelenmesi	EEG, anket, performans ölçümü	Alfa, teta, beta bant güçleri	ANOVA, Pearson korelasyonu	20	Gerçek
(McDonnell vd., 2023)	Kısmi araç içi otomasyonunda mental iş yükü ve görsel etkileşimin incelenmesi	EEG	Frontal teta, parietal alfa bant gücü	Ki-kare testi, ANOVA	71	Gerçek

Yapay zekâ, çalışma ortamı tasarımlarını insan beyninin bilişsel ve algısal yetenekleriyle uyumlu olacak şekilde optimize etmeyi amaçlayan nöroergonominin ilerlemesinde çok önemli bir rol oynamaktadır. Otomobil sürücüleri için nöroergonomi

alanında yapay zekanın etkisine bakılacak olursa, son yıllarda çeşitli alanlarda kullanımı oldukça yaygınlaşan makine öğrenmesi ve derin öğrenme algoritmalarının otomobil sürücüleri üzerinde de uygulanmaya başlandığı söylenebilir.

EEG sinyallerini kullanarak sürücülerin bilişsel yüklerini sınıflandıran ilk yapay zekâ çalışmalarından birinde, bir simülasyon sürüş görevinde ikincil bir görev (n-geri testi) eklenerek anlık mental iş yükündeki değişim incelenmiştir. Beş EEG bant gücü ve sekiz adet zaman bazlı EEG özniteliği arasından Komşuluk Bileşen Analizi ile öznitelik çıkarımı yapılmış ve Durum Tabanlı Çıkarsama ile gerçekleştirilen sınıflandırmada %70'in üzerinde doğruluğa ulaşılmıştır (Barua vd., 2017). Simülasyon sürüşü ile birlikte n-geri testinin uygulandığı bir diğer çalışmada, EEG bant gücü değerleri ve alfa, teta, beta bant güçleri ile hesaplanan bazı indeks değerleri (Alfa/Beta, Teta/Beta vb.) öznitelik olarak kullanılmıştır. Özniteliklerde boyut azaltma için PCA ve LDA kullanılmış ve SVM, Lojistik Regresyon, kNN ve YSA modelleri ile iki ve üç iş yükü seviyesi sınıflandırılmıştır. Katılımcı bazında en yüksek sınıflandırma performansı lineer SVM modeli ile elde edilmiştir (Bakshi, 2018).

Sürücülerin zihinsel iş yükünü belirleyebilmek için derin öğrenme modellerinden faydalanan ilk çalışmalardan birinde, CNN modeli ile düşük ve yüksek iş yükü ayrıştırılmıştır. Tek bir katılımcı ile gerçekleştirilen simülasyon sürüş görevinde dört elektrottan elde edilen ham EEG verisi kullanılmıştır. Önerilen modelin sürücünün zihinsel iş yükünü yüksek doğrulukla sınıflandırabildiği ve bu konuda büyük bir geliştirme potansiyeli olduğu belirtilmiştir (Almogbel vd., 2018).

Sürüş deneyleri çoğunlukla simülasyon ortamlarında gerçekleştirilmekle birlikte, gerçek sürüş görevleri sırasında ölçülen EEG sinyallerinin kullanıldığı uygulamalar da mevcuttur. (Di Flumeri vd., 2018) gerçek trafikte yirmi katılımcı ile gerçekleştirdikleri sürüş görevinde on bir elektrottan kaydettikleri EEG verilerinden 187 adet öznitelik oluşturmuşlardır. LDA modelinin özel bir hali ile en ilgili öznitelikler bulunarak ağırlıklandırılmış ve EEG tabanlı bir iş yükü indeksi geliştirilmiştir. Aynı deneylerde elde edilen veri üzerinde, öznitelik seçimi için CNN tabanlı oto kodlayıcı kullanıldığı çalışmada ise (Islam vd., 2019) SVM, kNN, RO ve MLP modelleri ile iki iş yükü sınıfı

(düşük ve yüksek) sınıflandırılmış, SVM ile en yüksek doğruluğa ulaşılmıştır. Benzer şekilde bir gerçek sürüş görevi ile EEG ölçümü yapılan bir çalışmada, bu kez aracın motor devri ve hızı gibi sürüşle ilgili verilerden EEG seviyelerini tahmin etmek amaçlanmıştır. Sekiz elektrottaki beta bant gücü ortalamaları ile etiketlenen sürüş verilerinden SVM modeli ile iki EEG seviyesi tahmin edilmiştir (Kim vd., 2019).

Makine öğrenmesi modellerinin sınıflandırma performansını etkileyen en önemli faktörlerden biri kullanılan özniteliklerin içeriği ve boyutudur. Ayrıca EEG sinyallerinin işlenmesindeki temel zorluklardan biri bilişsel durumları tanımlamak için uygun bilgiyi içeren özniteliklerin bulunmasıdır. Sürücülerin EEG verilerinden çıkarılan öznitelikler üzerinde bileşen analizi yöntemleri, LDA, MI gibi farklı öznitelik seçim yöntemleri uygulanmıştır. Gerçek sürüş görevindeki EEG verileri ile araç verileri arasındaki karşılıklı bilginin çıkarılmasını hedefleyen (Islam vd., 2020), çalışmalarında sundukları MI tabanlı öznitelik kümesinin sürücülerin zihinsel iş yükünü sınıflandırmak ve izlemek için kullanılabileceğini ileri sürmüşlerdir. Kırk beş adet EEG tabanlı öznitelik ile dört adet MI tabanlı özniteliği farklı makine öğrenmesi modelleri ile kıyaslamışlar ve en yüksek doğruluğa MI tabanlı öznitelikler ve RO modeli ile ulaşmışlardır. Bir simülasyon sürüş görevi ile n-geri testinin eş zamanlı olarak yürütüldüğü üç farklı senaryoda EEG verileri ile araç verileri kaydedilmiştir. Bu verilerden oluşturulan 323 öznitelik arasından Ardışık İleri Yönlü Kayan Seçim (Sequential Forward Floating Selection-SFFS) ve RO algoritmaları ile 42 öznitelikten oluşan bir optimal öznitelik kümesi seçilmiştir. Sınıflandırma aşamasında iki veya üç seviyeli iş yükünü sınıflandırmada en yüksek performansı RO modeli göstermiştir (Barua vd., 2020). Yüksek ve düşük bilişsel iş yüklerinin tanınmasını sağlayan kritik EEG özniteliklerinin seçimi için Genetik Algoritma ve Lojistik Regresyon tabanlı GALoRIS adı verilen bir algoritma önerilmiştir. GALoRIS bir simülasyon sürüş görevi ile test edilmiş, birden fazla EEG sinyalinden elde edilen bilgileri kullanarak orijinal veri kümesini %50'den fazla azalttığı ve modelin tahmin kapasitesini arttırdığı tespit edilmiştir. Dokuz elektrottan elde edilen beş EEG bandı için bu algoritma ile seçilen öznitelikler; F7 elektrotundaki delta bant gücü, AF4, F3, F7, F8, O2, P8 elektrotlarındaki alfa bant güçleri ve AF4 ve FC5 elektrotlarındaki beta bant güçleri olmuştur (Becerra-Sánchez vd., 2020). Öznitelik çıkarımı için Filtre Bankası Ortak Uzamsal Örüntü (Filter Bank

Common Spatial Pattern-FBCSP) algoritması kullanan Zhang (2021)'ın çalışmasında, simülasyon ortamında bir otonom sürüş görevi sırasında sürüşle ilgili olmayan diğer görevlerin iş yükü üzerindeki etkisinin incelenmesi amaçlanmıştır. Teta ve alfa bant güçlerine ilişkin özniteliklerin çıkarımı FBCSP ile tamamlanmış ve katılımcıların sübjektif mental iş yükü değerlendirmesine göre etiketlenerek, LDA ile sınıflandırılmıştır. Çalışmanın sonucunda yüksek düzeyde otonom sürüş sırasında beyin sinyallerinin çözülmesi yoluyla sürücünün kontrolü devralma sürecindeki performansının iyileştirildiği belirtilmiştir (Zhang, 2021).

Kişilerin görev talebini algılama şekillerinin ve zihinsel kapasitelerinin birbirinden farklı olması sebebiyle, aynı görevlerde bile maruz kaldıkları zihinsel iş yükleri farklılık gösterebilmektedir. Bu anlamda iş yükünü incelerken bireysel farklılıkları dikkate alan çalışmalar mevcuttur. Noh vd. (2021)'nin Kişiselleştirilmiş Sürücü İş Yükü Profili'ni sundukları çalışmalarında, EEG ve EKG verilerinden Beta/Alfa indeksi ile KAF değeri her katılımcı için ortak öznitelik olarak seçilmiş, diğer öznitelikler PCA ile katılımcıya özel olarak oluşturulmuştur. Bulanık C-Ortalamalar ile gerçekleştirilen kümeleme sonucunda; katılımcı-bazında (per-driver) elde edilen doğruluk değerleri, katılımcılar-arası (cross-driver) ortalama doğruluğa göre daha yüksek bulunmuştur.

İş yükü sınıflandırma modellerinde yeterince etkili ve hassas olması sebebiyle yalnızca EEG verisi kullanımının etkinliği kanıtlanmış olmasına rağmen, EEG ile birlikte farklı yöntemler ile elde edilen verilerin de kullanıldığı görülmektedir. Bu konuda kimi zaman Kim vd. (2019)'nin çalışmasında olduğu gibi diğer verilerden EEG seviyelerinin tahmin edilmesi, kimi zaman ise diğer verilerin EEG verisi ile birlikte girdi olarak kullanılması söz konusu olmaktadır. Kızılötesi Termal Görüntüleme öznitelikleri kullanılarak sürücülerin beta bant gücü ile temsil edilen mental iş yükünün tahmin edildiği bir çalışmada, düşük ve yüksek iş yükü seviyelerinin sınıflandırılmasında lineer SVM modeli kullanılmıştır (Perpetuini vd., 2022). Göz takibi, göz bebeği çapı ve EEG verisinin sürücülerin iş yükünün değerlendirilmesi açısından incelendiği bir çalışmada ise, göz bebeği çapının baseline ve ikinci seviye zorluktaki görev sırasında oluşan zihinsel iş yükünü %75 doğrulukla sınıflandırabildiği bulunmuştur. Ancak baseline ve

üç zorluk seviyesinde görevlerin ele alındığı bu çalışmada, sınıf sayısı üç veya dört olduğunda sınıflandırma performansı %58'in üzerine çıkamamıştır (Aygun vd., 2022).

Huang vd. (2022) sürücülerin fizyolojik sinyallerinden mental iş yükünün tahmini için üç farklı derin öğrenme modeli ile bir makine öğrenmesi modelini karşılaştırmışlardır. Bir simülasyon sürüş görevi sırasında on beş katılımcıdan elde edilen EEG, EKG, GSR ve KAF verilerini kullanarak altmış bir adet öznitelik çıkarılmış; Ekstrem Gradyan Arttırma (XGBoost), CNN, Evrişimli LSTM ve CNN ve LSTM'in bir kombinasyonundan oluşan derin öğrenme modeli ile dört iş yükü seviyesi tahmin edilmiştir. CNN ve LSTM modelinin en iyi performansı gösterdiği, XGBoost modelinin ise muhtemelen sınıf sayısının fazla olması sebebiyle düşük performans gösterdiği belirtilmiştir. Yang vd. (2023) ise sürücülerin mental iş yükünü EEG, EOG ve araç verilerinden yararlanarak gerçek zamanlı olarak tahmin edebilmek için ARecNet adını verdikleri bir hiper LSTM modeli geliştirmişlerdir. Geliştirilen model hafif, orta ve yoğun olmak üzere üç iş yükü seviyesini en yüksek %87,4 doğrulukla tahmin etmiştir.

Literatürde nörofizyolojik sinyallerden zihinsel durumların tespiti için sıklıkla farklı yöntemler kullanıldığı ve zihinsel iş yükü sınıflandırması için kullanılacak en iyi algoritmalar ile ilgili bir fikir birliğine varılmadığı görülmektedir (Borghini vd., 2014). Genel olarak kullanılan zihinsel iş yükü sınıflandırıcıları arasında; tek gizli katmanlı ileri beslemeli YSA, bulanık C-ortalamalı kümeleme, bulanık maksimum olasılık tahmini, kNN, SVM, CNN, derin inanç ağları, hiyerarşik Bayes modeli ve LDA sayılmıştır (Yin vd., 2019). Otomobil sürücülerinin zihinsel iş yükü sınıflandırması için kullanılan yöntemler arasında ise; lojistik regresyon, SVM, LDA ve YSA bulunmaktadır (Rahman vd., 2020). Çizelge 2.3'te otomobil sürücülerinin EEG sinyallerini kullanarak zihinsel iş yüklerinin sınıflandırılması konusunda gerçekleştirilen yapay zekâ çalışmaları özetlenmiştir.

Çizelge 2.3. Otomobil sürücülerinin zihinsel iş yükü hakkındaki yapay zekâ çalışmaları

Kaynak	Katılımcı Sayısı	Deney Ortamı	Sınıf Sayısı	Öznitelik Çıkarımı	Sınıflandırma Yöntemi	Performans
(Barua vd., 2017)	36	Simülasyon	2	Komşuluk Bileşen Analizi	Durum Tabanlı Çıkarsama	%70
(Bakshi, 2018)	28	Simülasyon	2, 3	PCA ve LDA	SVM, Lojistik Regresyon, kNN ve YSA	%99,1
(Almogbel vd., 2018)	1	Simülasyon	2	-	CNN	%95,31
(Di Flumeri vd., 2018)	20	Gerçek	2	Otomatik-durdurma-kademeli LDA (asSWLDA)		%74,4
(Kim vd., 2019)	28	Gerçek	2	Manuel	SVM	%74,28
(Islam vd., 2019)	20	Gerçek	2	CNN-Otokodlayıcı	SVM, kNN, RO, MLP	%94
(Islam vd., 2020)	20	Gerçek	2	MI	Lineer Regresyon, Lojistik Regresyon, MLP, RO ve SVM	%94
(Barua vd., 2020)	66	Simülasyon	2, 3	Ardışık İleri Yönlü Kayan Seçim ve RO	kNN, SVM, RO	%80
(Becerra-Sánchez vd., 2020)	*	Simülasyon	2	Genetik Algoritma ve Lojistik Regresyon, PCA ve MI	SVM, Lineer Regresyon ve kNN	%96,14
(Noh vd., 2021)	40	Gerçek	3	PCA	SVM, Bulanık C-Ortalamalar	%97
(Zhang, 2021)	15	Simülasyon	2	Filtre Bankası Ortak Uzamsal Örüntü (FBCSP)	LDA	%89,3
(Huang vd., 2022)	15	Simülasyon	4	-	XGBoost, CNN, Evrişimli LSTM ve CNN+LSTM	%97,8
(Perpetuini vd., 2022)	15	Simülasyon	2	PSD	SVM	%73,6
(Aygun vd., 2022)	80	Simülasyon	2, 3, 4	ICA, Fourier Dönüşümü	kNN, Naive Bayes, RO, SVM, YSA	%75
(Yang vd., 2023)	14	Simülasyon	3	ICA, Fourier Dönüşümü	Hiper LSTM	%87,4
* belirtilmemiş						

3. MATERYAL ve YÖNTEM

Bu bölümde, öncelikle tez çalışmasının veri toplama aşamasında kullanılan ölçüm yöntemleri (NASA-TLX, EEG) hakkında teorik bilgiler verilmiştir. Devamında tez çalışması kapsamında yürütülen deneysel prosedür ve EEG verilerinin analizi hakkında detaylı bilgiler paylaşılmıştır. Son olarak sınıflandırma aşamasında kullanılan makine öğrenmesi modellerinden (SVM, kNN, RO ve YSA) bahsedilerek modellerin uygulanması hakkında bilgilere yer verilmiştir.

3.1. Veri Toplama Aşaması

Bu tez çalışmasında, otomobil sürücülerinin mental iş yüklerinin incelenmesi için sübjektif ve objektif yöntemler yoluyla veri toplanmıştır. NASA-TLX ile sürüş sırasındaki görev yükü sürücülerin kendi değerlendirmeleri yoluyla alınırken, EEG yöntemi ile sürücülerin sürüş sırasındaki beyin elektriksel aktivitesi ölçülmüştür. Bu bölümde NASA-TLX ve EEG yöntemleri ile ilgili bilgi verilmektedir.

3.1.1. NASA Görev Yükü İndeksi (NASA-TLX)

NASA Görev Yükü İndeksi Hart ve Staveland (1988) tarafından geliştirilmiş bir iş yükü değerlendirme yöntemidir. Katılımcıların gerçekleştirdikleri iş esnasında maruz kaldıklarını düşündükleri altı alt faktörü (zihinsel zorluk, fiziksel zorluk, geçici zorluk, performans, çaba/kaygı) puanlamaları ve bu faktörleri birbirleriyle karşılaştırarak ağırlıklandırmaları yoluyla uygulanır. Güvenilirliği kanıtlanan bu yöntem çok çeşitli ortamlar ve faaliyet türleri için uygulanabilmektedir.

NASA-TLX yönteminde değerlendirilen altı alt faktörün açıklamaları şu şekildedir:

1. Zihinsel Talep: Düşünme, karar verme, hesaplama, hatırlatma, bakma, arama gibi zihinsel ve algılama aktivitelerine ne kadar ihtiyaç duyuluyor? Görev hatasız ve kesin mi yapılmalı yoksa hata kabul edilebilir mi? Görev kolay mı zor mu? Görev basit mi karışık mı?

2. Fiziksel Talep: İttirme, çekme, çevirme, kontrol etme, çalıştırma gibi fiziksel aktivitelere ne kadar ihtiyaç duyuluyor? Görev rahat mı yorucu mu, yavaş mı hızlı mı, gelişigüzel yapılabiliyor mu, özel bir özen istiyor mu?
3. Geçici Zorluk (Zamansal Talep): Belirli bir görevin bir aşamasını yerine getirirken ne kadar zaman baskısı veya kısıtı hissediliyor? Görevi yerine getirmek için hareketlerin yavaş mı hızlı mı olması gerekiyor?
4. Performans: Verilen görevin hedeflerine ulaşmada size göre veya denetçilere göre ne derece başarılı olduğunuzu düşünüyorsunuz? Görevi yerine getirirken ne derece tatmin oluyorsunuz?
5. Çaba: Görevinizi yerine getirmek için zihinsel ve fiziksel olarak ne kadarlık ağır çalışma gereklidir?
6. Kaygı-Boşa Çaba: Görev esnasında kendinizi ne kadar güvensiz, yılgın, tedirgin, stres altında veya gergin hissettiniz?

NASA-TLX uygulaması üç adımdan oluşmaktadır: oranlama, ağırlıklandırma ve genel iş yükünü hesaplama. Oranlama aşamasında altı alt faktör "çok düşük" ve "çok yüksek" ölçeğinde işaretlenir. Bu işaretlere karşılık gelen değerler ağırlıklandırılmamış iş yükü değerleridir. Ağırlıklandırma aşamasında katılımcılar altı alt faktörün iş yüküne katkılarını dikkate alarak İkili Karşılaştırma Tekniği ile faktörleri birbirleriyle karşılaştırır. Yapılan on beş karşılaştırmada her alt faktörün kaç kez seçildiğine göre bir ağırlık değeri elde edilir. Genel iş yükü indeksi ise oranlama ve ağırlıklandırma aşamasında elde edilen değerler ile Denklem (3.1)'deki gibi hesaplanır (Hart & Staveland, 1988).

$$TLX = MD * W_{MD} + PD * W_{PD} + TD * W_{TD} + PL * W_{PL} + EL * W_{EL} + FL * W_{FL} \quad (3.1)$$

NASA-TLX yönteminin farklılaştırılmış uygulamaları da mevcuttur. NASA-TLX ile arasında güçlü bir korelasyon bulunması sebebiyle araştırmacılar tarafından kabul edilen ve yaygın şekilde kullanılan NASA Ham Görev Yükü İndeksi (NASA-RTLX) bunlardan biridir (Byers vd., 1989). Bu tez çalışmasında her bir sürüş deneyi sonrasında hızlı bir şekilde iş yükünü ölçümleyebilmek için NASA-RTLX kullanılmıştır. NASA-RTLX yönteminde altı alt faktörün ağırlıkları eşit kabul edilerek, iş yükü indeksinin

hesaplanmasında yalnızca ağırlıklandırılmamış iş yükü değerleri kullanılmaktadır. Ham iş yükü indeksi (3.2) numaralı denklem ile hesaplanmaktadır.

$$RTLX = {}^{(MD + PD + TD + PL + EL + FL)}/_{6} \quad (3.2)$$

Hesaplanan iş yükü indeksinin değeri 0-20 aralığında ise "çok düşük", 21-40 aralığında ise "düşük", 41-59 aralığında ise "orta", 60-79 aralığında ise "yüksek" ve 80-100 aralığında ise "çok yüksek" olarak değerlendirilmektedir (Riono vd., 2018).

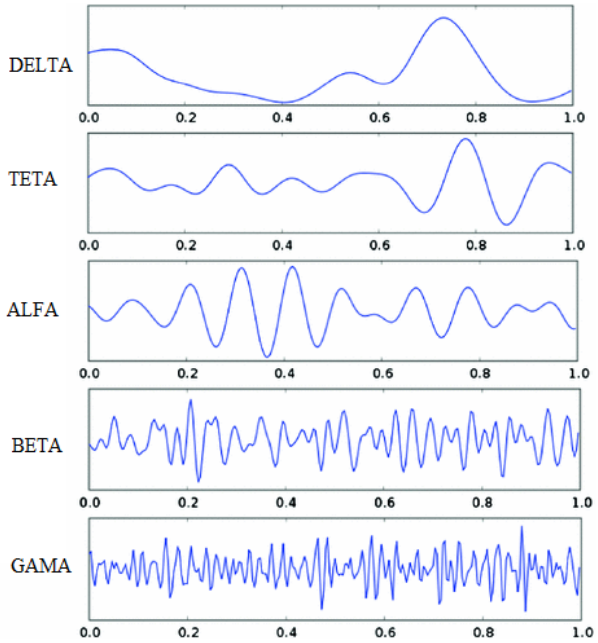
Tez çalışmasında kullanılan NASA-RTLX uygulama sayfası EK 1'de verilmiştir.

3.1.2. Elektroensefalografi (EEG)

EEG saçlı deri üzerinden kafaya bağlanan iletken elektrotlar vasıtasıyla beynin belirli bölgelerindeki aktivite sırasında oluşan elektriksel sinyallerin ölçülmesini sağlayan bir yöntemdir. Sinir hücreleri tarafından üretilen elektriksel sinyalleri ölçen EEG cihazları beyindeki aktiviteyi, olası işlev bozukluklarını ve yerlerini tespit etmeyi sağlar (Niedermeyer ve da Silva, 2005). EEG elektrotları genellikle iletken jeller ile saçlı deriye bağlanır. Elektrotlar Uluslararası 10-20 Sistemi adı verilen yerleştirme tekniği ile, bitişik elektrotlar arasındaki mesafeler kafatasının toplam ön-arka mesafesinin %10'u ve sağ-sol mesafesinin %20'si olacak şekilde yerleştirilir (Homan vd., 1987).

EEG nöroergonomi çalışmalarında en sık kullanılan bilişsel yük ölçüm araçlarından biridir. Diğer nöro-görüntüleme yöntemleri ile karşılaştırıldığında en yüksek zamansal çözünürlüğü sağlayan yöntem olarak ön plana çıkmaktadır. Diğer sistemlere göre daha ucuz olması, tüm beyin bölgelerindeki aktiviteyi aynı anda ölçebilmesi ve aynı zamanda kablosuz ve taşınabilir hale getirilmesinin de mümkün olması sebebiyle birçok alanda daha avantajlı hale gelmektedir. Kablosuz özellikli taşınabilir EEG cihazlarının hızlı bir gelişim göstermesiyle birlikte laboratuvar dışındaki gerçek yaşam koşullarında nispeten rahat kullanıcılar üzerinde ölçüm yapılması mümkün olmaktadır (Niso vd., 2023).

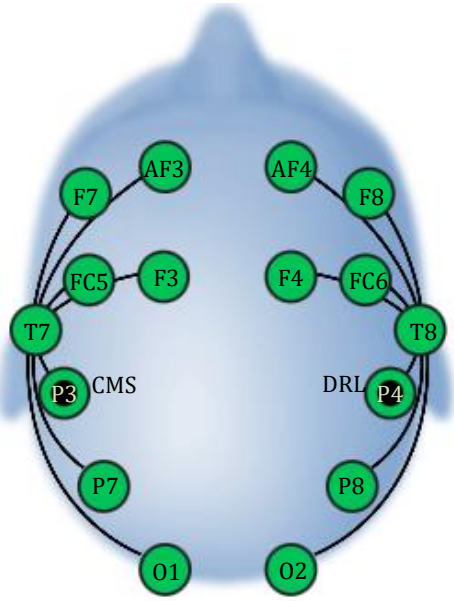
EEG sinyallerinin farklı frekanslarında görülen ritmik ve tekrarlayıcı modellere beyin dalgası adı verilmektedir. Şekil 3.1'deki gibi gözlemlenen delta, teta, alfa, beta ve gama dalgaları farklı bilinç durumları ve faaliyetlerle ilişkilendirilmektedir. 0,5-4 Hz aralığında görülen Delta dalgaları tamamen derin uykuda ortaya çıkmaktadır. 4-8 Hz aralığında oluşan Teta dalgaları çok derin rahatlama hali veya derin düşünme ile ilişkilendirilir. 8-12 Hz aralığında Alfa dalgaları oluşur ve genellikle fazla sakin, rahat halde ortaya çıkar. 12-30 Hz aralığında oluşan Beta dalgaları uyanık, dikkatli ve aktif durumda görülür. 30 Hz ve üzerinde görülen Gama dalgaları ise yüksek derecede konsantrasyon ve odaklanma halinde ortaya çıkmaktadır. (Abhang vd., 2016).



Şekil 3.1. Beyin dalgaları (Siuly vd., 2016)

Beyin dalgalarının oluşumunun yanı sıra aktivasyonun beynin hangi bölgesinde gerçekleştiği de önemli bir konudur. Frontal bölge karar verme ve derin düşünmeyle, parietal bölge kişinin dış ortamla ilişkisiyle, oksipital bölge görme duyusuyla ilgili alanlardır. Yaygın günlük görevlerle ilişkili beyin aktivitesini inceleyen nöroergonomi çalışmalarında, farklı beyin bölgelerinin bağlantılarını tanımlamak için bazı korelasyon tabanlı yaklaşımlar kullanılmaktadır (Posner, 2012).

Bu tez çalışmasında, bahsedilen avantajlı özellikleri sebebiyle Emotiv EPOC X kablosuz EEG cihazı ve EmotivPRO yazılımı kullanılmıştır. Uluslararası 10-20 Sistemi'ne göre yerleştirilen on dört elektrottan (AF3, AF4, F3, F4, FC5, FC6, F7, F8, T7, T8, P7, P8, O1, O2) ölçüm alınmıştır (Şekil 3.2). AF3, AF4, F3, F4, FC5, FC6, F7, F8 frontal bölgedeki, T7 ve T8 temporal bölgedeki, P7 ve P8 parietal bölgedeki, O1 ve O2 ise oksipital bölgedeki kanallardır. P3 ve P4 lokasyonlarındaki CMS ve DRL ise iki kulağın arkasındaki mastoid kemik üzerine yerleştirilen referans elektrotlardır. Örnekleme hızı 128 Hz ve çözünürlüğü 14 bittir.



Şekil 3.2. Elektrotların yerleşimi

EEG sinyallerindeki gürültüyü temizlemek için EmotivPRO yazılımının yerleşik dijital 5. derece Sinc filtresi ve 50/60 Hz'deki çentik filtreleri kullanılmıştır. Her kanalın teta (4-8 Hz), alfa (8-12 Hz), düşük beta (12-16 Hz), yüksek beta (16-25 Hz) ve gama (25-45 Hz) bantlarının bant güçleri bir saniyelik epoklar için hesaplanmıştır. EEG sinyalleri kaydedilirken atılan işaretleyiciler (marker) sayesinde sinyaller rotanın bölümlerine göre ayrıştırılmıştır.

3.2. Katılımcılar

Gerçek trafik deneylerine toplam 39 sağlıklı katılımcı (16 kadın, 23 erkek) şahsi otomobilleriyle gönüllü olarak katılmıştır. Katılımcıların yaşları 24 ile 55 aralığında olup, yaş ortalaması 39,13 ve sürüş tecrübesi ortalaması 16,66 yıldır. Yıllık ortalama sürüş mesafesi 21600 km'dir. Katılımcılar aşağıdaki kriterleri sağlamıştır:

1. 18-60 yaş aralığında olmak,
2. B sınıfı ehliyet sahibi olmak,
3. En az bir yıldır aktif otomobil kullanıyor olmak,
4. Otomobil sürmeye engel olabilecek bir sağlık sorunu bulunmamak,
5. Deney öncesinde yorucu ve ağır bir iş yapmamak,
6. Deney öncesinde alkol, sigara vb. madde kullanmamak.

Deney öncesinde her katılımcıya sürüş rotası ve ölçümler hakkında detaylı bilgi verilmiş, EK 2'de görülen Katılımcı Bilgi ve Onay Formu imzalatılmıştır. Tez kapsamında gerçekleştirilen deneysel çalışma Bursa Uludağ Üniversitesi Fen ve Mühendislik Bilimleri Araştırma ve Yayın Etik Kurulu tarafından 2020-03/3 karar numarası ile onaylanmıştır.

Katılımcıların yaşlarının sürüş sırasında kaydedilen EEG sinyalleri üzerindeki etkisini inceleyebilmek için katılımcılar yaşlarına göre üç gruba ayrılmıştır. Yaşa göre oluşturulan gruplar şu şekildedir:

- Grup 1: 18-30 yaş arasındaki katılımcılar
- Grup 2: 31-50 yaş arasındaki katılımcılar
- Grup 3: 51 yaş ve üzerindeki katılımcılar

Katılımcıların sürüş tecrübelerinin sürüş sırasında kaydedilen EEG sinyalleri üzerindeki etkisini incelemek amacıyla katılımcılar otomobil sürme tecrübelerine göre üç gruba ayrılmıştır. Sürüş tecrübesine göre oluşturulan üç grup şu şekildedir:

- Grup 1: 10 yıldan daha az sürüş tecrübesine sahip katılımcılar
- Grup 2: 10-20 yıl arasında sürüş tecrübesine sahip katılımcılar
- Grup 3: 20 yıldan daha fazla sürüş tecrübesine sahip katılımcılar

3.3. Deneysel Prosedür

Tez çalışmasının deney aşamasında katılımcıların şahsi otomobilleri ile gerçek trafikte sürüş deneyleri gerçekleştirilmiştir. İlk olarak bir katılımcı ile şehir içi ara yol ve ana yol olmak üzere iki farklı rotada kısa süreli pilot deneyler gerçekleştirilmiştir. Her sürüş görevi öncesi otuz saniye boyunca sakin hal (baseline) kaydı alınmıştır. Bu deneylerin devamında gerçek trafik deneylerinin gerçekleştirilebileceği sürüş rotaları üç gönüllü katılımcı ile test edilmiştir. Yapılan bu testlerde her bir EEG kaydı öncesi katılımcıdan bir dakika uzunluğunda tek bir sakin hal kaydı almanın daha faydalı olacağı fark edilmiştir. Ayrıca ölçümün ayrı rotalarda ve farklı seferlerde yapılması, EEG kaydını zorlaştırmakta ve sürücüyü zihinsel olarak etkilemektedir. Bu sebeple tüm deneyin bir dakikalık bir sakin hal kaydı, ardından altı farklı bölümü içeren tek bir turdan oluşan rota üzerinde yapılmasına karar verilmiştir.

Deneylerin gerçekleştirildiği rota, Bursa Uludağ Üniversitesi Görükle Kampüsü ve çevresindeki ara sokaklar, ana yol ve otoyol bağlantı yolundan oluşan sıralı bölümlerden meydana gelecek şekilde belirlenmiştir (Şekil 3.3). Rotanın her bölümde farklı yol tipi, trafik yoğunluğu, hız ve yol karmaşıklığı koşulları bulunmaktadır (Çizelge 3.1). Bölüm 1 ile başlayan rota, devamında sırasıyla Bölüm 2, 3, 4, 5 ve 6 ile devam etmekte ve ardından duraklama olmadan Bölüm 4, 3, 2 ve 1 ile sona ermektedir. Bölüm 5 ve Bölüm 6, yolun aynı kısımları olmasına rağmen, bu bölümlerdeki ortalama hız farklıdır. Bu sebeple ayrı bölümler olarak dikkate alınmışlardır.

Çizelge 3.1. Deney rotasının bölümleri hakkında bilgiler

Bölüm	Yol Tipi	Trafik Yoğunluğu	Maksimum Hız (km/sa)	Yol Karmaşıklığı
1	Şehir içi ara yol	Düşük	50	Düz, az dönüş
2	Şehir içi ara yol	Yüksek	50	Yaya geçidi ve kavşak
3	Şehir içi ara yol	Orta	50	Yaya geçidi ve kavşak
4	Şehir içi ana yol	Yüksek	82	Düz, az dönüş
5	Şehir dışı yol (otoyol)	Düşük	90	Az dönüş
6	Şehir dışı yol (otoyol)	Orta	120	Az dönüş, trafik lambası



Şekil 3.3. Deney rotası

Deneyler sabah saatlerinde (08.30-11.30 saatleri arasında) belirlenen rota üzerinde gerçekleştirilmiştir. Her deney yaklaşık otuz dakika sürmüştür. Tamamen gerçek bir sürüş ortamı sağlamak amacıyla deney öncesinde katılımcılara rota ve rotanın bölümleri hakkında bilgi verilmiştir. Katılımcılar alışkın oldukları şahsi otomobilleriyle deneye katıldığından her deneyde vites tipi vb. araca ait özellikler değişkenlik göstermiştir. Deneyden önce her katılımcıdan günlük hayatta olduğu gibi otomobil sürmeleri istenmiş, deney sırasında kafa hareketlerini azaltmaları ve mümkün olduğunca konuşmamaları konusunda bilgi verilmiştir. Hava koşulları gibi sürüşü etkileyebilecek

çevresel etmenler açısından tüm deneylerin benzer koşullarda yapılmasına dikkat edilmiş, ekstrem durumlarda deney gerçekleştirilmemiştir.

Emotiv EPOC X katılımcının kafasına yerleştirdikten sonra EmotivPRO yazılımı kullanılarak bağlantı kalitesi ve EEG kalitesi kontrol edilmiştir. Sürüş görevine başlamadan önce tüm kanalların bağlantı kalitesinin %100 olması sağlanmıştır. Gözler açık ve kapalı olmak üzere otuzar saniye boyunca toplam bir dakikalık sakin hal (baseline) ölçümünün hemen ardından sürüş görevi başlatılmıştır.

Deney sırasında otomobilde sürücüyle birlikte tek bir kişi bulunmuş, çok gerekli haller dışında konuşmadan ve sürücüye herhangi bir müdahalede bulunmadan verileri kaydetmiştir. Deney sürecinin aşamaları Şekil 3.4'te özetlenmiştir. Gerçekleştirilen deneylerde deneye hazırlık aşaması, sakin hal ölçümü ve sürüş sırasında alınan görüntülerden bazı örnekler ise Şekil 3.5'te görülmektedir.



Şekil 3.4. Deneysel prosedür



Şekil 3.5. Deneylerden görüntüler
A) Hazırlık aşaması **B)** Sakin hal ölçümü **C)** Sürüş aşaması

Rotanın bölümleri birbiri ardına geldiğinden ve ara verilmeden bir sürüş gerçekleştirildiğinden dolayı NASA-TLX anketini her bir bölüm için ayrı ayrı uygulamak mümkün olmamıştır. Bu sebeple katılımcıların bölüm bazında zihinsel zorluk değerlendirmelerini alabilmek için, NASA-TLX anketi uygulamasından sonra, zihinsel zorluk faktörünü rotanın her bölümü için ayrı ayrı değerlendirmeleri istenmiştir. NASA-TLX anketindeki ölçeğe benzer şekilde, katılımcı rotadaki her bir bölümü zihinsel zorluk açısından 0-100 arasında puanlamıştır. Burada amaç, rotadaki bölümlerin sürücü üzerindeki zihinsel zorluk etkisini sübjektif olarak ölçebilmektir.

3.4. EEG Veri Analizi

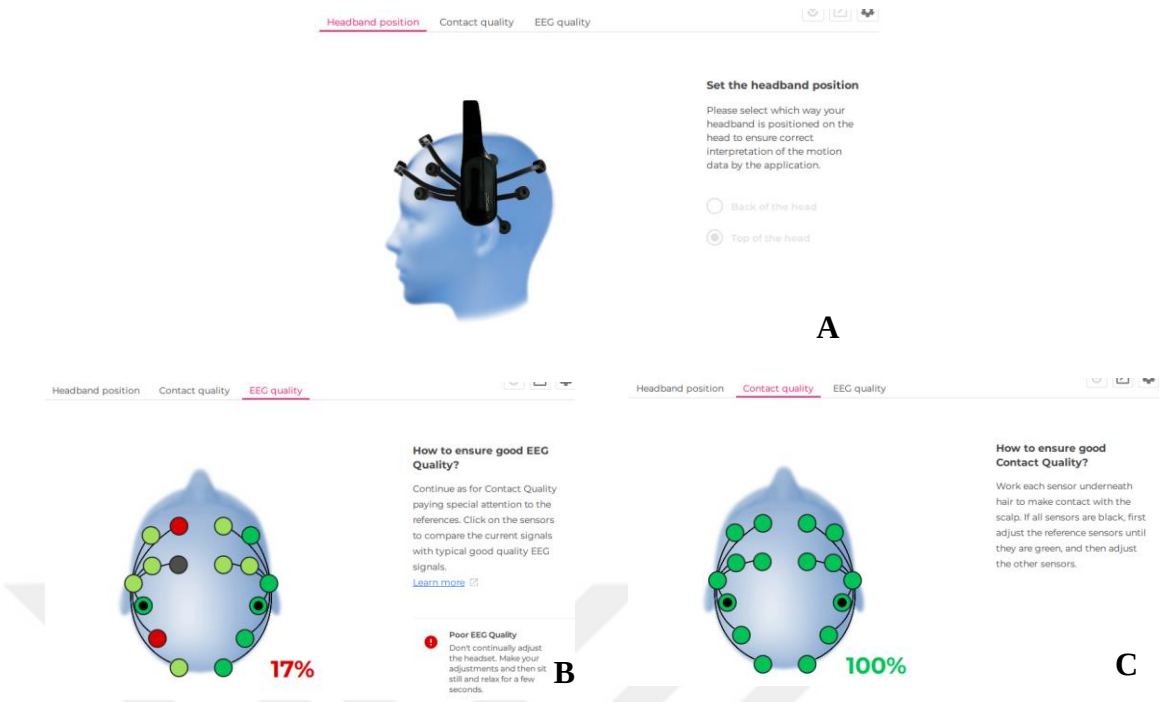
3.4.1. EEG sinyal kalitesi

EmotivPRO yazılımında sinyal kalitesi ile ilgili *bağlantı kalitesi* ve *EEG kalitesi* olmak üzere iki parametre gösterilmektedir. Bu tez çalışmasında deneyler gerçek trafikte otomobil sürüşü esnasında yapıldığından, sürücünün hareketlerinin sinyal kalitesi üzerindeki etkisi önem arz etmektedir. Bağlantı kalitesi kanalın empedansının bir ölçüsüdür. Elektrotların iletken solüsyon ile doğru ıslatılması ve saçlı deri ile doğru şekilde temas ettirilmesi yoluyla empedans düşürülerek bağlantı kalitesi arttırılabilmektedir. EmotivPRO yazılımında sinyal kalitesi ile ilgili hesaplanan diğer parametre olan EEG kalitesi ise, yazılıma gömülü makine öğrenmesi algoritmalarıyla bağlantı kalitesi ve sinyal genliğine bağlı olarak 1-4 arasında bir değer olarak hesaplanmaktadır.

Deneye hazırlık aşamasında tüm kanallar için empedansın düşürülerek ve iyi bir bağlantı kalitesi sağlanarak, toplam *bağlantı kalitesinin* %100 olmasına dikkat edilmiştir. *EEG kalitesi* ise, deney esnasında sürekli değişmektedir. Özellikle sürücünün hareketinin arttığı kısımlarda azalmaktadır. EEG ölçümü sırasında her bir kanala ait sinyal genliği ve bant güçleri kaydedilirken, *EEG kalitesi* de kaydedilmektedir. Bu tez çalışmasında EEG tabanlı mental durum indeksleri hesaplanırken, kanal bazında *EEG kalitesi* değerleri dikkate alınmıştır. Bu şekilde çalışmaya özel bir "kaliteli sinyal oranı" hesaplaması yapılmıştır. Eğer kanallardan en az %50'sinin o örneklemdeki (satırdaki) *EEG kalitesi* değeri üç veya dört ise, o örneklem kaliteli kabul edilmektedir. Sonuçta verideki kaliteli örneklem sayısı toplam örneklem sayısına oranlanarak "kaliteli sinyal oranı" hesaplanmaktadır (Denklem 3.3).

$$Kaliteli\ Sinyal\ Oranı = \frac{Kaliteli\ Örneklem\ Sayısı}{Toplam\ Örneklem\ Sayısı} \tag{3.3}$$

Deneye hazırlık aşamasında Emotiv EPOC X cihazının bağlantısı yapılırken, EmotivPRO yazılımından bağlantı ve sinyal kalitelerinin kontrolüne ilişkin görüntüler Şekil 3.6'da verilmiştir.



Şekil 3.6. Bağlantı ve sinyal kalitelerinin kontrolü
A) Cihaz yerleşiminin seçilmesi **B)** EEG Kalitesi değerleri **C)** Bağlantı kalitesi değerleri

3.4.2. EEG tabanlı mental durum indeksleri

Bu tez çalışmasında araştırılmak üzere literatürde kullanılan ve beyindeki EEG sinyallerinin teta, alfa ve beta bantlarındaki spektral güçlerini içeren üç mental durum indeksi belirlenmiştir:

- İndeks 1 = Frontal Teta / Parietal Alfa (Holm vd., 2009)
- İndeks 2 = Orta Frontal Teta (Yamada, 1998)
- İndeks 3 = (Alfa + Teta) / Beta (Jap vd., 2009)

Bu indeksler alfa, teta ve beta bant güçlerinin ilgili kanallar bazında ortalaması alınarak hesaplanmaktadır. İyi bilinen mental iş yükü göstergeleri olan Frontal Teta/Parietal Alfa oranı ile Orta Frontal Teta değerinin yanı sıra beta bandını da dikkate alan bir göstergeyi araştırmak amaçlanmıştır. Bu çalışmada tartışmak üzere mental yorgunluk göstergesi olarak da ele alınan (Alfa+Teta)/Beta oranı seçilmiştir.

İndeks değerleri, her bir katılımcının teta, düşük beta, yüksek beta ve alfa bant gücü değerleri kullanılarak sürüş rotasının her bir bölümü için hesaplanmıştır. *E* kümesi tüm EEG elektrotlarını içeren kümeyi temsil ederken, *Fr*, *Fm* ve *Par* sırasıyla frontal, orta frontal ve parietal bölge elektrotlarını içermektedir. İndeks 1 (I_1) sekiz frontal elektrotundan ölçülen teta bant gücünün ortalamasının, iki parietal elektrottan alınan alfa bant gücünün ortalamasına bölünmesiyle hesaplanır (Denklem 3.4). İndeks 2 (I_2) F3 ve F4 elektrotlarından ölçülen teta bant güçlerinin ortalamasıdır (Denklem 3.5). İndeks 3 (I_3) ise on dört elektrotun tümü için teta bant güçleri ve alfa bant güçlerinin toplamının beta bant gücüne bölünmesiyle oluşturulur (Denklem 3.6).

$E = \{AF3, AF4, F3, F4, FC5, FC6, F7, F8, P7, P8, T7, T8, O1, O2\}$
$Fr = \{AF3, AF4, F3, F4, FC5, FC6, F7, F8\}$
$Fm = \{F3, F4\}$
$Par = \{P7, P8\}$
$Teta\{X\} =$ *X elektrotundaki teta bant g*ücü
$Alfa\{X\} =$ *X elektrotundaki alfa bant g*ücü
$Beta\{X\} =$ *X elektrotundaki d*üşü*k ve y*ü*ksek beta bant g*üç*lerinin ortalaması*
olmak üzere

$$I_1 = \frac{\sum Teta\{\forall X \in Fr\}/8}{\sum Alfa\{\forall X \in Par\}/2} \quad (3.4)$$

$$I_2 = \frac{\sum Teta\{\forall X \in Fm\}}{2} \quad (3.5)$$

$$I_3 = \frac{\sum Alfa\{\forall X \in E\} + \sum Teta\{\forall X \in E\}}{\sum Beta\{\forall X \in E\}}/14 \quad (3.6)$$

şeklinde hesaplanmaktadır.

Mental durum indekslerinin EEG sinyallerinden hızlı ve doğru bir şekilde hesaplanabilmesi için Microsoft Office Excel ortamında bir VBA uygulaması hazırlanmıştır. VBA uygulamasında girdi olarak on dört elektrottan alınan sinyallerin teta, alfa, düşük beta ve yüksek beta bant güçleri kullanılmaktadır. Çıktı olarak ise kaliteli sinyal oranları ve üç farklı formüle sahip mental durum indeksleri deneydeki sakin hal ve aktif sürüş bölümleri için ayrı ayrı hesaplanmaktadır.

3.5. Mental iş yükü sınıflandırma aşaması

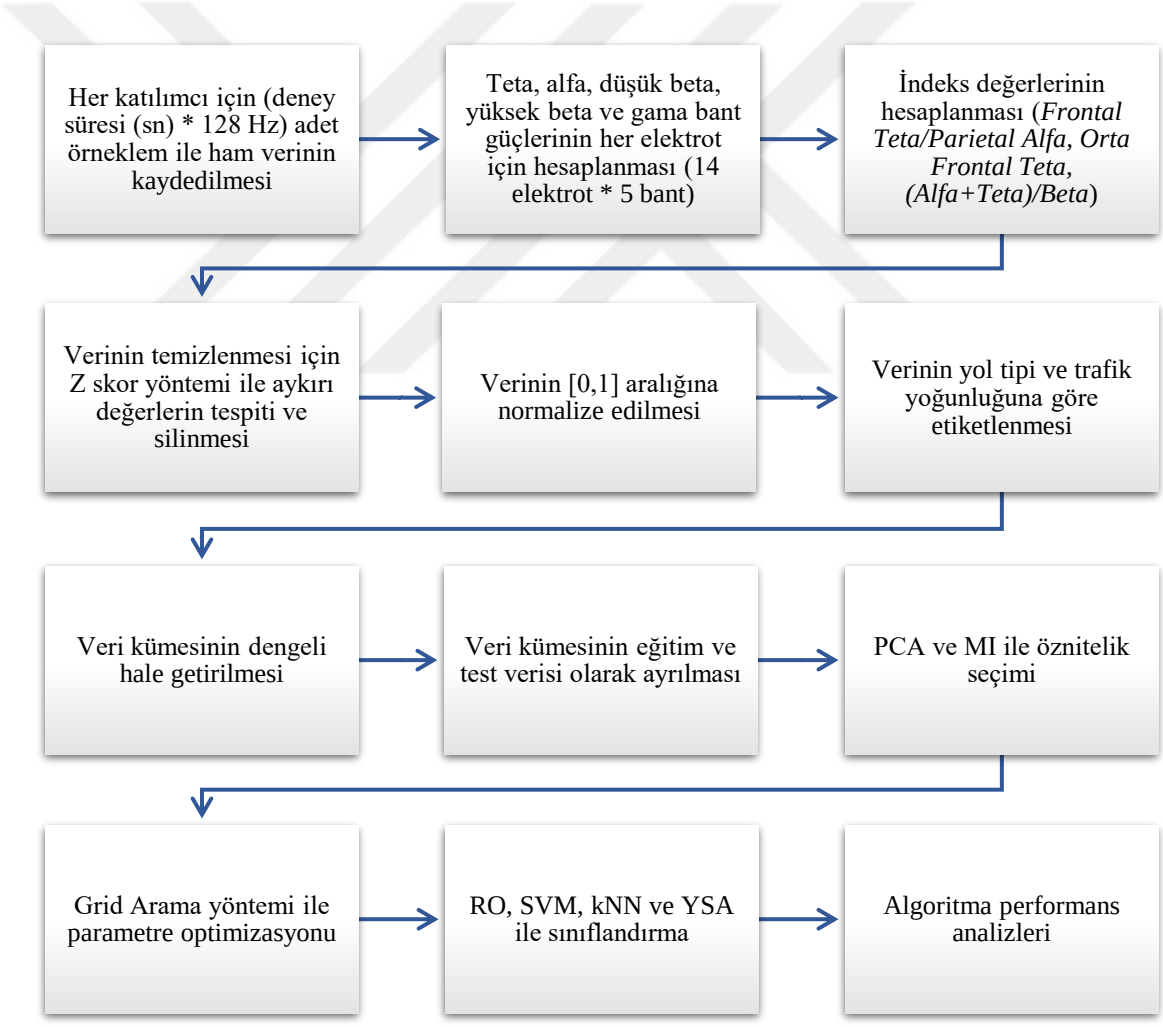
Yapay zeka ve makine öğrenmesi algoritmaları; tahmin, sınıflandırma, görüntü işleme, doğal dil işleme, ses tanımlama, karar verme ve optimizasyon gibi birçok uygulama alanında etkin bir şekilde kullanılmaktadır. EEG sinyallerinin sınıflandırılması için de doğrusal regresyon, lojistik regresyon, YSA, SVM, kNN, karar ağaçları, RO, Naive Bayes ve LDA modellerinden yararlanılmaktadır.

Bu tez çalışmasında sürücülerin gerçek trafikte kaydedilen EEG sinyallerinden hesaplanan bant gücü ve mental durum indeks değerleri öznitelik olarak kullanılmış, sürücülerin zihinsel iş yükü RO, SVM, kNN ve YSA modelleri ile sınıflandırılmıştır. Kullanılan bu makine öğrenmesi algoritmaları hakkında bazı temel bilgiler aşağıda açıklanmaktadır:

a. Rassal Orman (RO): Veriler ve sınıfları verilen bir karar ağacı algoritması, sınıflandırma yapmak için gerekli kuralları üretir. Karar düğümleri ve yaprak düğümleri olan bir ağaç yapısına sahiptir. Karar ağacında kök düğüm en belirleyici parametreyi, yaprak düğümler o aşamada yapılan sınıflandırmayı ya da kararı temsil eder. En az sayıda karşılaştırma ile doğru sınıfı bulmak için bir karar ağacı oluşturulurken bilgi kazancı ve entropi kavramları kullanılır (Çelik, 2009). RO algoritması ise sınıflandırma sırasında birden fazla karar ağacı kullanılarak sınıflandırma değerinin yükseltilmesini hedefleyen bir algoritmadır. Bir verinin sınıfını belirlemek için farklı rassal karar ağacı biçimlerinden alınan bilgileri toplar (Rigatti, 2017).
b. Destek Vektör Makineleri (SVM): Veri kümesinde birbirine benzeyen sınıflar arasına, birbirine en uzak noktalardan sınırlar çizmeye yarayan bir algoritmadır. Birbirine en yakın veri noktaları arasında bir hiper-düzlem çizerek sınıfları ayırır ve aralarındaki mesafeyi en yükseğe çıkarmayı hedefler (Çelik, 2009).
c. K En Yakın Komşu Algoritması (kNN): Çalışma mantığı, sınıfı öğrenmek istenen bir verinin en yakın k tane komşusuna bakıp, komşularının çoğu hangi sınıftaysa o verinin de aynı sınıfa koyulması şeklindedir. Eğitim için gürültülü veri daha rahat kullanılabilir ve uygulaması kolaydır (Kramer, 2013).

d. Yapay Sinir Ağları (YSA): Bir YSA, giriş vektörünü bazı çıktılara dönüştüren, katmanlar halinde düzenlenmiş nöronlardan oluşur. Her katman, girdi olarak aldığı veriyi genellikle doğrusal olmayan bir yöntemle kullanıp çıktısını bir sonraki katmana aktarır. Bir YSA oluşturulurken katman sayısı ve katmanlardaki nöron sayıları belirlenir. Ağın eğitilmesi ise her katmanda nöronların ağırlıklarının güncellenerek belirlenmesi yoluyla gerçekleşmektedir (Kotsiantis vd., 2007).

Bu tez çalışmasında EEG sinyalleri üzerinden mental iş yükünün sınıflandırılmasında izlenen aşamalar Şekil 3.7'de verilmiştir.



Şekil 3.7. EEG sinyalleri ve makine öğrenmesi ile mental iş yükü sınıflandırma süreci

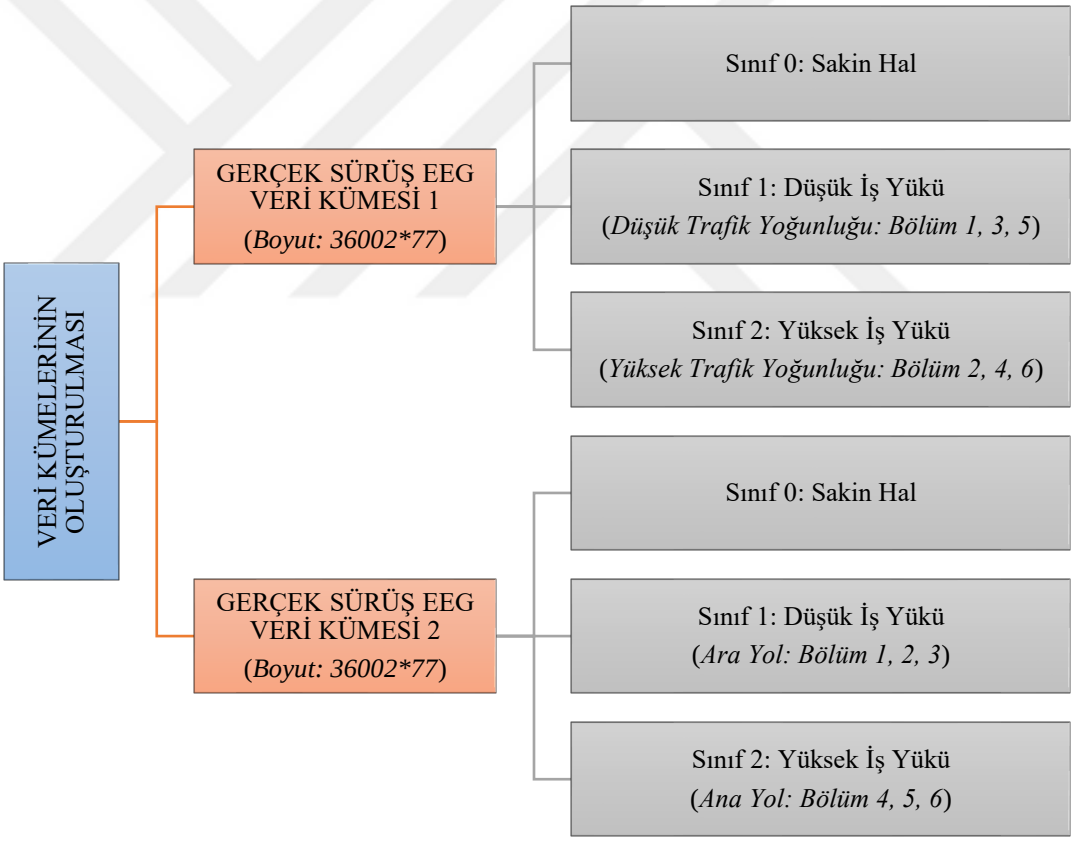
İlk aşamada veri toplamı işlemi gerçekleştirilmiştir. EEG sinyallerinden hesaplanan teta, alfa, düşük beta, yüksek beta ve gama bant güçleri (14 elektrot * 5 bant), hesaplanan mental durum indeksleri (üç adet) ve kişisel faktörler (üç adet) olmak üzere toplam 76 adet öznitelik, algoritmada girdi olarak alınmıştır (Çizelge 3.2).

Çizelge 3.2. Zihinsel iş yükü sınıflandırmasında kullanılan öznitelikler

Öznitelik Tipi	Öznitelik Açıklaması
EEG Bant Güçleri	AF3_Teta, AF4_Teta, F3_Teta, F4_Teta, FC5_Teta, FC6_Teta, F7_Teta, F8_Teta, T7_Teta, T8_Teta, P7_Teta, P8_Teta, O1_Teta, O2_Teta
	AF3_Alfa, AF4_Alfa, F3_Alfa, F4_Alfa, FC5_Alfa, FC6_Alfa, F7_Alfa, F8_Alfa, T7_Alfa, T8_Alfa, P7_Alfa, P8_Alfa, O1_Alfa, O2_Alfa
	AF3_DüşükBeta, AF4_DüşükBeta, F3_DüşükBeta, F4_DüşükBeta, FC5_DüşükBeta, FC6_DüşükBeta, F7_DüşükBeta, F8_DüşükBeta, T7_DüşükBeta, T8_DüşükBeta, P7_DüşükBeta, P8_DüşükBeta, O1_DüşükBeta, O2_DüşükBeta
	AF3_YüksekBeta, AF4_YüksekBeta, F3_YüksekBeta, F4_YüksekBeta, FC5_YüksekBeta, FC6_YüksekBeta, F7_YüksekBeta, F8_YüksekBeta, T7_YüksekBeta, T8_YüksekBeta, P7_YüksekBeta, P8_YüksekBeta, O1_YüksekBeta, O2_YüksekBeta
	AF3_Gama, AF4_Gama, F3_Gama, F4_Gama, FC5_Gama, FC6_Gama, F7_Gama, F8_Gama, T7_Gama, T8_Gama, P7_Gama, P8_Gama, O1_Gama, O2_Gama
Mental Durum İndeksleri	Frontal Teta / Parietal Alfa
	Orta Frontal Teta
	(Alfa+Teta)/Beta
Kişisel Faktörler	Yaş
	Cinsiyet
	Sürüş Tecrübesi

EEG ölçümlerinden elde edilen sinyallerin eğitim verisi olarak kullanımı için veri ön işleme aşaması gerçekleştirilmiştir. Bu aşamada öncelikle verideki aykırı değerler Z Skoru yöntemi ile tespit edilmiştir. Bir örneklem için Z skoru $Z = {(x - \mu)}/{\sigma}$ formülü ile hesaplanmış, Z skoru [-3,3] aralığının dışında kalan örneklemler aykırı değer olarak işaretlenmiştir. Belirlenen aykırı değerler veri kümesinden çıkarılmıştır. Daha sonra tüm değerler [0,1] aralığında olacak şekilde normalizasyon yapılmıştır.

Veri etiketleme aşamasında çalışmaya özgü iki farklı yaklaşım benimsenmiştir: *i)* rotanın bölümlerini trafik yoğunluğuna göre ayırmak ve *ii)* rotanın bölümlerini yol tipine göre ayırmak. Bu etiketleme yaklaşımları ile iki farklı veri kümesi oluşturulmuştur. Trafik yoğunluğu seviyeleri düşük ve yüksek, yol tipleri ise ara yol ve ana yol şeklinde ele alınmıştır. Her iki durumda sakin hal ile birlikte veri kümesindeki sınıf sayısı üç olmaktadır. Elde edilen ilk bulgularda ara yoldaki ortalama zihinsel iş yükünün ana yola göre daha düşük olduğu belirlenmiştir. Ayrıca trafik yoğunluğunun az olduğu bölümlerde ortalama zihinsel iş yükünün, trafik yoğunluğunun yüksek olduğu bölümlere göre daha düşük olduğu görülmüştür. Zihinsel iş yükü sınıflarının bu bulgulara göre etiketlenmesiyle oluşturulan veri kümelerine ve sınıf özelliklerine ilişkin bilgiler Şekil 3.8'de verilmiştir.



Şekil 3.8. İki farklı veri etiketleme yaklaşımı ile oluşturulan veri kümeleri ve özellikleri

Sakin hal ölçümü diğer sürüş bölümlerine göre daha kısa sürdüğü için Sınıf 0'da daha az örneklem bulunmaktadır. Bu nedenle sınıflar arasında bir veri dengesizliği mevcuttur. Sentetik Azınlık Aşırı Örnekleme Tekniği (SMOTE) yöntemi (Chawla vd., 2002) ile bir

veri arttırma işlemi yapılarak sınıflardaki verinin dengeli hale gelmesi sağlanmıştır. Veri dengeleme işlemi sonrasında Gerçek Sürüş EEG Veri Kümesi 1'de toplam 56627 örneklem, Gerçek Sürüş EEG Veri Kümesi 2'de ise toplam 56631 örneklem bulunmaktadır.

Sınıflandırmada iki farklı yaklaşım ele alınmıştır:

i) Katılımcılar-arası (cross-subject) ve

ii) *K*atılımcı-bazında (per-subject) sınıflandırma.

Burada temel amaç, beyin aktivitesindeki bireysel farklılıkların makine öğrenmesi modellerinin sınıflandırma performansını ne şekilde etkileyeceğinin incelenmesidir. Katılımcılar-arası sınıflandırma için tüm katılımcıların verisi bir arada toplanarak tek bir veri kümesi oluşturulmuş, toplamda 36002 adet örneklem kullanılmıştır. Veri kümesinin boyutu [*36002*77*]'dir. Katılımcı-bazında sınıflandırma için ise her bir katılımcının verisi deney süresine göre değişen sayıda örneklemden oluşan bir veri kümesi olarak alınmıştır. Burada veri kümelerinin boyutları [*o deneydeki örneklem sayısı*77*] şeklindedir.

Veri kümesi eğitim ve test verisi olarak ayrılırken, eğitim-test verisi oranlarının %70-%30, %80-%20 ve %90-%10 olduğu alternatifler denenmiştir. Öznitelik seçim aşamasında EEG sinyallerinden öznitelik seçimi veya çıkarımı için en sık kullanılan yöntemler olarak bilinen Temel Bileşen Analizi (PCA) ve Karşılıklı Bilgi (MI) (Becerra-Sánchez vd., 2020) kullanılmıştır. PCA ve MI tabanlı öznitelik kümelerinin kullanıldığı ve öznitelik seçiminin yapılmadığı durumlar için sınıflandırma performansları karşılaştırılmıştır. Öznitelik sayısı için {10, 20, 30, 40, 50, 60, 70} değerlerinin her biri denenerek verdikleri sonuçlar incelenmiştir.

Makine öğrenmesi modellerinin tahmin doğruluğunu arttırmak için en uygun model parametresi değerlerini belirlemek amacıyla önceden belirlenmiş tüm olası parametre kombinasyonlarını kapsamlı bir şekilde araştıran ve model performanslarını sistematik olarak değerlendiren Grid Arama yöntemi kullanılmıştır. Grid Arama ile araştırılan model parametreleri Çizelge 3.3'te görülmektedir. Model parametrelerinin en iyi

değerleri belirlenmiş ve bu değerler kullanılarak eğitim verisi ile SVM, kNN, RO ve YSA modellerinin öğrenme aşaması gerçekleştirilmiştir. Son olarak test verileri ile modellerin performansı belirlenmiştir.

Çizelge 3.3. Grid Arama ile araştırılan model parametreleri

Model	**Parametre**	**Parametre Değerleri**
SVM	Kernel fonksiyonu	Lineer, polinomiyal, radyal temelli, sigmoid
	Kernel katsayısı (gama)	$1/N$, $1/(N * var(X))$
kNN	Komşu sayısı	3, 5, 7, 9, $\sqrt{S}$
	Algoritma	BallTree (Top ağacı), KDTree (K boyutlu ağaç), Brute force (kaba kuvvet) algoritmaları, otomatik
	Ağırlık fonksiyonu	Düzgün, mesafeye bağlı
RO	Ağaç sayısı	100, 200, 300, 500
	Ağaçtaki maksimum seviye sayısı	1, 2, 3, 4, sınırsız
	Kriter	Gini impuritesi, Shannon entropisi
YSA	Çözücü	lbfgs (Quasi-Newton yöntemi), sgd (stokastik gradyan iniş), adam (stokastik gradyan temelli optimizasyon yöntemi)
	Aktivasyon fonksiyonu	Aktivasyon yok, lojistik sigmoid, hiperbolik tanjant, ReLU (Rectrified linear unit)
	Öğrenme oranı	Sabit (0,001), Kademeli azaltma (invscaling), Uyarlanabilir (adaptive)
	Gizli katman sayısı ve boyutları	(10,), (10,10,), (100,), (100,100,)
N: öznitelik sayısı, var(X): öznitelik dizisinin varyansı, S: örneklem sayısı		

Sınıflandırma modellerinin performansını değerlendirmek üzere kullanılan metrikler arasında karmaşıklık matrisi (confusion matrix), doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1 skoru sayılabilir. Bu tez çalışmasında model performansları doğruluk cinsinden belirlenmiş ve karşılaştırılmıştır. Doğruluk değeri doğru pozitif (TP), doğru negatif, yanlış pozitif ve yanlış negatif değerleri ile Denklem 3.7'deki hesaplanmaktadır. Burada doğru pozitif modelin gerçekte var olan bir durumu pozitif göstermesi, doğru negatif gerçekte var olmayan bir durumu negatif göstermesi, yanlış pozitif gerçekte var olmayan bir durumu onaylaması ve yanlış negatif ise gerçekte var olan bir durumu reddetmesi olarak ifade edilebilir.

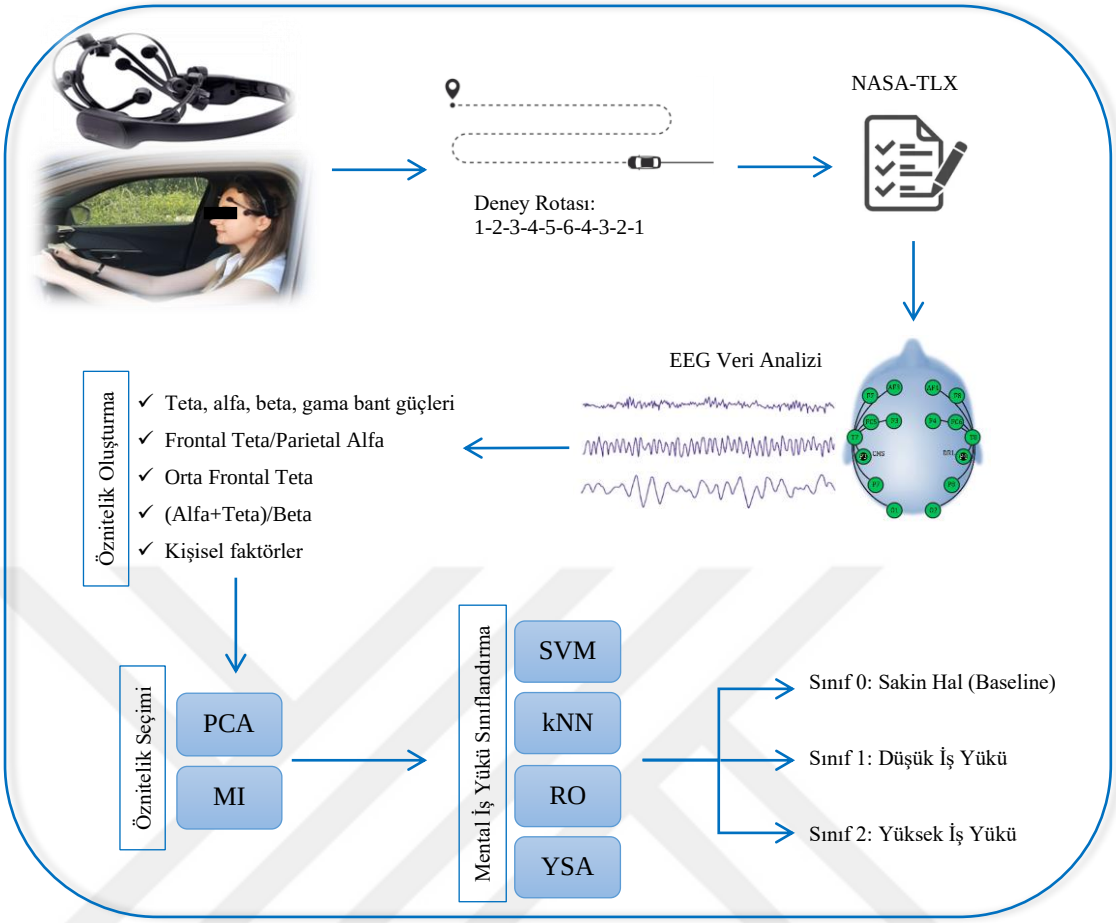
$$Doğruluk = \frac{TP+TN}{TP+FP+TN+FN} \tag{3.7}$$

Katılımcılar arası ve katılımcı bazında zihinsel iş yükü sınıflandırma modellerinin doğrulukları arasındaki farkın istatistiksel anlamlılığı Kruskal-Wallis Testi ile test edilmiş, ardından farkın hangi modeller arasında oluştuğunun belirlenmesi için Mann-Whitney U Testi uygulanmıştır. Bu amaçla test edilen hipotezler şu şekildedir:

- H_0: Zihinsel iş yükü sınıflandırma modellerinin doğruluk değerleri arasında anlamlı bir fark yoktur.
- H_1: Zihinsel iş yükü sınıflandırma modellerinin doğruluk değerleri arasında anlamlı bir fark vardır.

Sınıflandırma modellerinin uygulanması aşamasında tüm işlemler Python 3.10 programlama dilinde Pandas (versiyon 2.0.3), Numpy (versiyon 1.24.3), SciKit-Learn (versiyon 1.2.2) ve Matplotlib (versiyon 3.7.1) kütüphaneleri kullanılarak gerçekleştirilmiştir. Tez çalışmasındaki tüm istatistiksel hesaplamalar ve testler ise Minitab 18.1 istatistik paket programı ile gerçekleştirilmiştir.

Bu tez çalışmasının veri toplama, analiz ve makine öğrenmesi uygulama aşamalarının genel bir gösterimi Şekil 3.9'da verilmiştir.



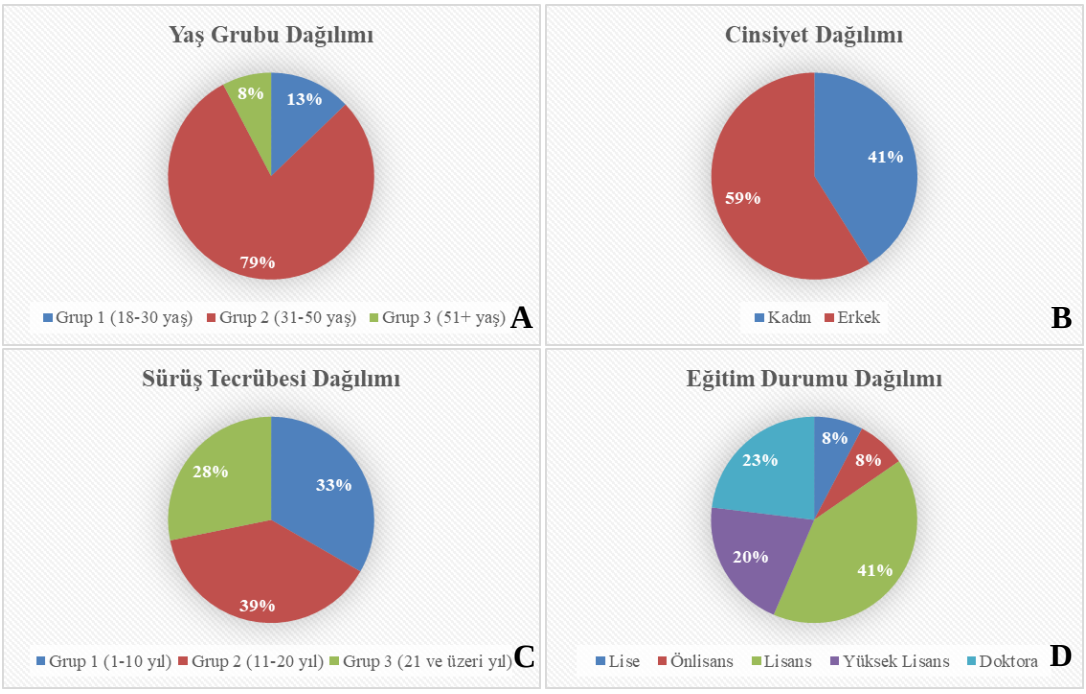
Şekil 3.9. Çalışmanın genel gösterimi

4. BULGULAR

Bu bölümde, ilk olarak sürüş deneyleri ile elde edilen verilerin analizi ve istatistiksel olarak değerlendirilmesi sonucunda elde edilen bulgular sunulmuştur. Sonrasında katılımcılar-arası ve katılımcı-bazında mental iş yükü sınıflandırma için gerçekleştirilen makine öğrenmesi uygulamasının sonuçlarından bahsedilmiştir.

4.1. Katılımcılar

Gerçek trafikteki sürüş deneylerine katılan 39 gönüllü katılımcının yaş, cinsiyet, eğitim durumu ve otomobil sürme tecrübesi gibi bilgilerine ait grafikler Şekil 4.1'de sunulmuştur. Buna göre katılımcıların büyük çoğunluğu 31-50 yaş arasında iken, %13'ü 18-30 yaş aralığında ve %8'i 51 yaş ve üzerindedir. Katılımcıların %59'u erkek, %41'i kadındır. Katılımcıların sürüş tecrübesi homojen bir dağılım göstermektedir. Sürüş tecrübesi 1-10 yıl arası olan katılımcıların oranı %33, 11-20 yıl arası olan katılımcıların oranı %39, 21 yıl ve üzeri olan katılımcıların oranı %28'tir. Eğitim durumu incelendiğinde ise; katılımcıların çoğunun (%41) lisans mezunu olduğu görülmektedir.



Şekil 4.1. Katılımcı demografik bilgilerinin dağılımı
A) Yaş **B)** Cinsiyet **C)** Sürüş tecrübesi **D)** Eğitim durumu

4.2. EEG Veri Analizi

Deneyler sırasında kaydedilen EEG sinyalleri için, öncelikle Emotiv EPOC X cihazının bağlantı kalitesi ve EEG kalitesi değerleri kullanılarak kaliteli sinyal oranları hesaplanmıştır. Tez çalışmasında dikkate alınmak üzere kaliteli sinyal oranı değeri için sınır değer %70 olarak belirlenmiştir. Hesaplanan kaliteli sinyal oranlarının dağılımı incelendiğinde, verilerin %79,5'inin %70 ve üzerinde kaliteli sinyal oranına sahip olduğu görülmüştür.

Her katılımcı için bölüm bazında; ortalama alfa, teta, beta bant güçleri, mental durum indeks değerleri, NASA-TLX skorları, yaş, cinsiyet, otomobil sürme tecrübesi değerlerini içeren bir veri kümesi oluşturulmuştur. Bu veri kümesinde toplam 468 (39 katılımcı * 12 bölüm) satır veri bulunmaktadır. Burada bahsedilen on iki bölüm şunları içermektedir: İki sakin hal ölçümü, rotanın ilk dört bölümünün ikişer tekrarı, beşinci bölüm ve altıncı bölüm. Kaliteli sinyal oranı %70 ve üzerinde olan veriler ise toplam 372 adettir. Tüm hesaplamalar, yeterli kalitede olduğu belirlenen bu veriler dikkate alınarak gerçekleştirilmiştir.

Alfa, teta ve beta bant gücü değerlerinin tanımlayıcı istatistikleri Çizelge 4.1'de verilmiştir. Tamamı sağa çarpık bir dağılıma sahiptir ve basıklık değerleri yüksektir. Anderson-Darling Normalite Testi ile aşağıdaki hipotezler test edilmiştir:

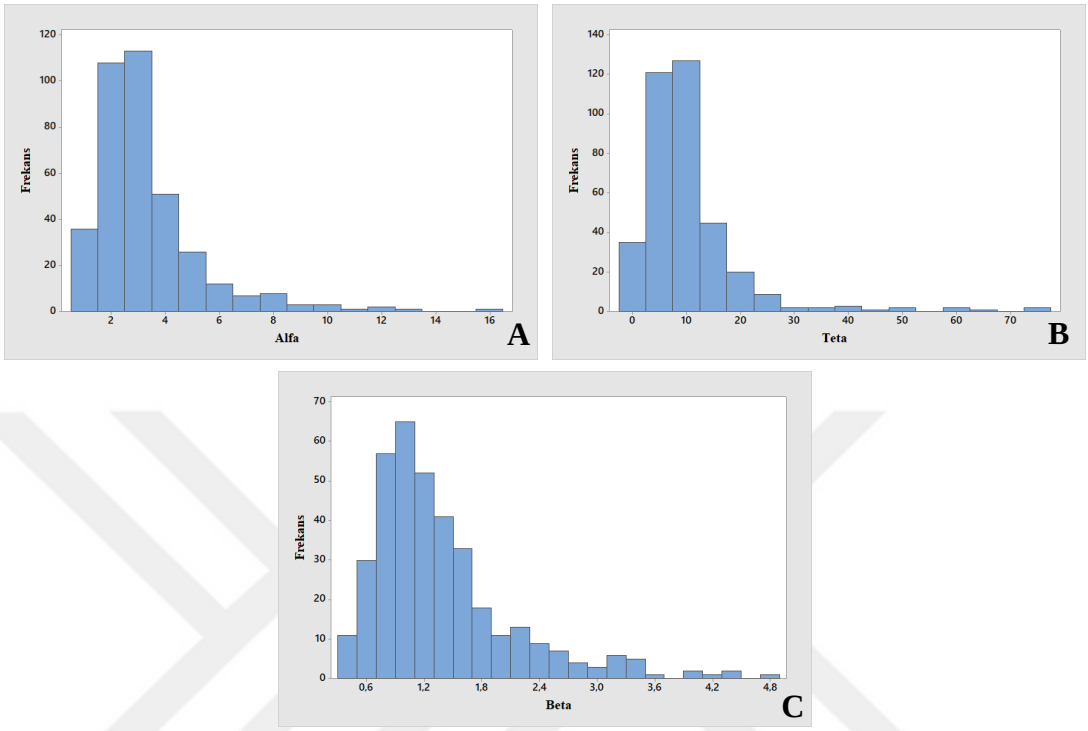
- H_0: Bant gücü verisi normal dağılıma uymaktadır.
- H_1: Bant gücü verisi normal dağılıma uymamaktadır.

Test sonucunda tüm p değerleri 0,005'ten küçük bulunduğundan, bant gücü verisinin normal dağılıma uymadıkları tespit edilmiştir.

Çizelge 4.1. Alfa, teta, beta bant gücü tanımlayıcı istatistikleri

Değişken	Örneklem Sayısı	Ortalama	Standart Sapma	Minimum	Maksimum	Çarpıklık	Basıklık
Alfa bant gücü	372	3,329	2,040	0,506	16,143	2,30	7,68
Teta bant gücü	372	10,517	9,951	0,833	75,888	3,46	15,96
Beta bant gücü	372	1,383	0,748	0,376	4,863	1,67	3,37

Alfa, teta ve beta bant gücü değerlerinin dağılımları Şekil 4.2'de verilen histogramlarda görülmektedir.



Şekil 4.2. Bant gücü değerlerinin histogramları
A) Alfa **B)** Teta **C)** Beta

Alfa, teta ve beta bant gücü değerleri rotanın bölümleri bazında incelenmiştir. Bu değişkenlerin gözler açık ve kapalı sakin hal ve rotanın her bir bölümü için tanımlayıcı istatistik değerleri Çizelge 4.2'de, grafikleri ise Şekil 4.3'te görülmektedir. Çizelge ve şekillerdeki Sakin Hal 1 ifadesi gözler açık sakin hali, Sakin Hal 2 ifadesi gözler kapalı sakin hali ifade etmektedir.

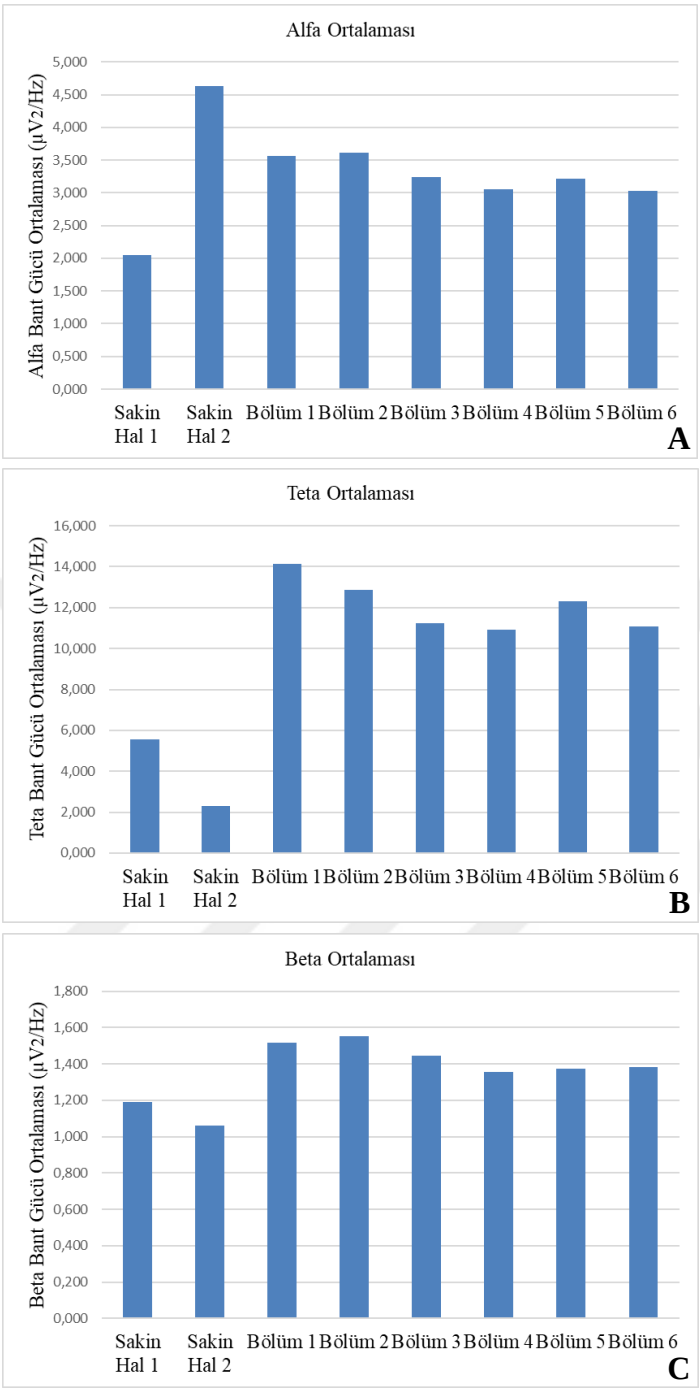
Bant gücü ortalamalarının bölümler arasında farklılık gösterip göstermediğini tespit edebilmek için, parametrik olmayan testlerden Kruskal-Wallis Testi uygulanmıştır. Hipotezler aşağıdaki gibi kurulmuştur:

- H_0: Bant gücü ortalamaları bakımından rotanın bölümleri arasında anlamlı bir fark yoktur.
- H_1: Bant gücü ortalamaları bakımından rotanın bölümleri arasında anlamlı bir fark vardır.

Test sonucunda tüm p değerleri 0,001'den küçük bulunmuştur. Dolayısıyla rotanın bölümleri arasında alfa, teta ve bant güçleri bakımından anlamlı fark olduğu söylenebilir.

Çizelge 4.2. Alfa, teta, beta bant gücü değerlerinin bölüm bazında tanımlayıcı istatistikleri

Değişken		N	Ortalama	St. Sapma	Minimum	Maksimum
Alfa	Sakin Hal 1	34	2,047	1,194	0,794	6,098
	Sakin Hal 2	38	4,626	3,410	0,506	16,143
	Bölüm 1	56	3,564	2,029	1,096	12,188
	Bölüm 2	58	3,609	1,690	1,309	10,313
	Bölüm 3	61	3,246	1,862	1,294	12,217
	Bölüm 4	63	3,059	1,501	1,108	9,355
	Bölüm 5	31	3,212	1,936	1,281	9,635
	Bölüm 6	31	3,030	1,646	1,364	9,629
Teta	Sakin Hal 1	34	5,554	3,584	1,482	13,093
	Sakin Hal 2	38	2,284	1,603	0,833	8,411
	Bölüm 1	56	14,14	13,00	4,03	75,89
	Bölüm 2	58	12,86	8,57	3,61	48,33
	Bölüm 3	61	11,22	8,59	3,36	52,36
	Bölüm 4	63	10,94	9,07	2,97	67,20
	Bölüm 5	31	12,30	13,39	3,60	74,38
	Bölüm 6	31	11,07	10,35	3,90	60,91
Beta	Sakin Hal 1	34	1,190	0,965	0,404	4,198
	Sakin Hal 2	38	1,061	0,632	0,376	3,018
	Bölüm 1	56	1,517	0,750	0,701	4,863
	Bölüm 2	58	1,5514	0,6930	0,6650	3,3210
	Bölüm 3	61	1,4436	0,7440	0,6120	4,0810
	Bölüm 4	63	1,3550	0,6908	0,4980	4,3020
	Bölüm 5	31	1,376	0,686	0,502	3,210
	Bölüm 6	31	1,384	0,793	0,559	4,410



Şekil 4.3. Rotanın bölümleri için bant gücü ortalamaları **A)** Alfa **B)** Teta **C)** Beta

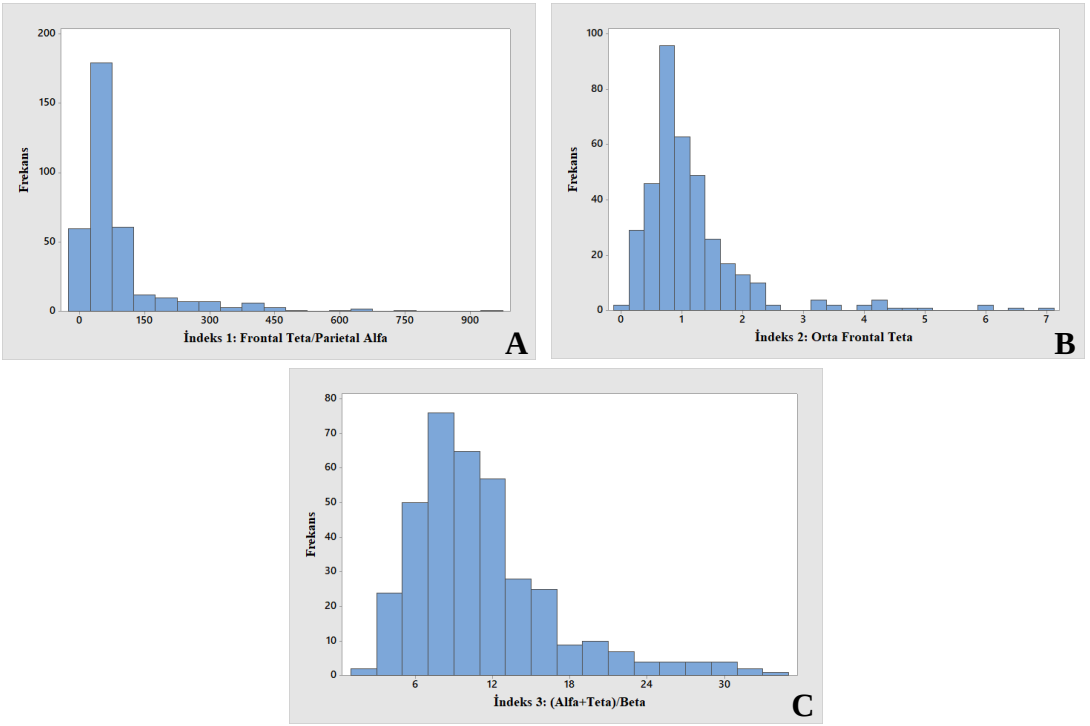
Mental durum indeksleri için de tanımlayıcı istatistikler ve rotanın bölümleri bazında ortalamalar hesaplanmıştır. Anderson-Darling Normalite Testi uygulamak üzere kurulan hipotezler aşağıdaki gibidir:

- H_0: Mental durum indeks verisi normal dağılıma uymaktadır.
- H_1: Mental durum indeks verisi normal dağılıma uymamaktadır.

Üç indeks değeri için de test sonucu p değeri 0,005'ten küçük bulunduğundan normal dağılıma uymadıkları sonucuna ulaşılmıştır. İndeks değerlerinin tanımlayıcı istatistikleri Çizelge 4.3'te, histogramları ise Şekil 4.4'te verilmiştir. Tamamının dağılımı sağa çarpıktır. İndeks 1 ve 2'nin basıklık değerleri yüksektir, İndeks 3'ün basıklık değeri ise üçten küçüktür. İki katılımcının parietal bölge elektrotlarındaki bağlantı kalitesinin deneyin bir kısmında çok düşük olması sebebiyle İndeks 1'in hesaplanamadığı on sekiz örneklem oluşmuştur. Çizelge 4.3'te görüldüğü gibi İndeks 1 için örneklem sayısı 354'tür.

Çizelge 4.3. İndeks değerleri tanımlayıcı istatistikleri

Değişken	Örneklem Sayısı	Ortalama	Standart Sapma	Minimum	Maksimum	Çarpıklık	Basıklık
İndeks 1	354	89,160	115,820	1,240	935,160	3,42	14,85
İndeks 2	372	1,164	0,942	0,083	7,008	2,99	11,69
İndeks 3	372	11,273	5,702	2,793	34,738	1,47	2,57



Şekil 4.4. İndeks değerleri histogramları **A)** İndeks 1 **B)** İndeks 2 **C)** İndeks 3

Mental durum indeksleri de sürüş rotasının bölümleri bazında incelenmiştir. İndekslerin sakin hal ve rotanın bölümleri için tanımlayıcı istatistikleri Çizelge 4.4'te, grafikleri ise Şekil 4.5'te görülmektedir.

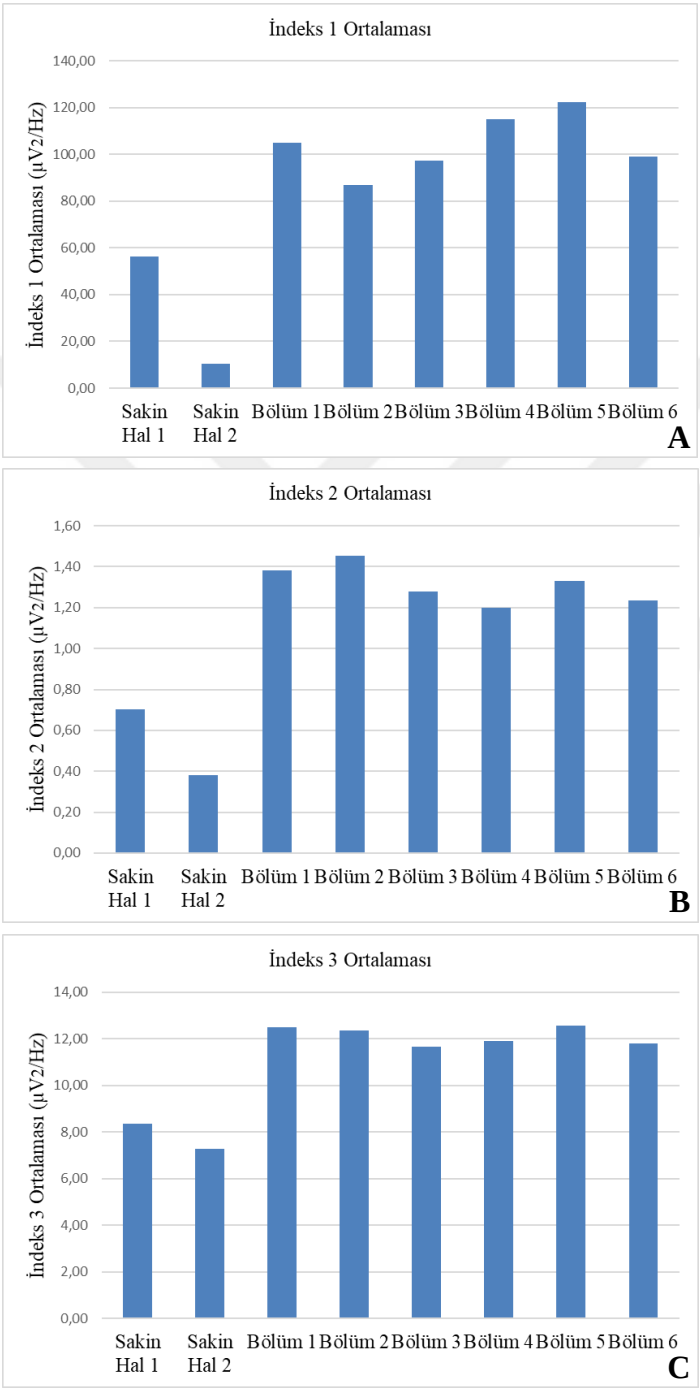
Çizelge 4.4. Mental durum indekslerinin bölüm bazında tanımlayıcı istatistikleri

Değişken		N	Ortalama	St. Sapma	Minimum	Maksimum
İndeks 1	Sakin Hal 1	33	56,35	44,66	8,66	174,41
	Sakin Hal 2	37	10,32	9,56	1,24	48,86
	Bölüm 1	53	105,0	106,5	18,6	511,6
	Bölüm 2	55	87,0	82,9	18,9	422,5
	Bölüm 3	57	97,4	110,9	20,2	634,9
	Bölüm 4	59	115,0	161,7	17,3	935,2
	Bölüm 5	30	122,2	169,4	19,3	726,2
	Bölüm 6	30	99,0	103,6	17,9	396,3
İndeks 2	Sakin Hal 1	34	0,7041	0,4782	0,1620	2,0410
	Sakin Hal 2	38	0,3813	0,1948	0,0830	0,8140
	Bölüm 1	56	1,383	0,889	0,528	4,586
	Bölüm 2	58	1,452	1,046	0,384	6,041
	Bölüm 3	61	1,277	0,865	0,361	5,106
	Bölüm 4	63	1,199	0,905	0,316	6,419
	Bölüm 5	31	1,331	1,303	0,336	7,008
	Bölüm 6	31	1,234	0,969	0,321	5,887
İndeks 3	Sakin Hal 1	34	8,360	5,342	3,436	25,975
	Sakin Hal 2	38	7,286	3,556	2,793	19,472
	Bölüm 1	56	12,500	5,725	5,247	34,738
	Bölüm 2	58	12,349	5,575	5,277	30,760
	Bölüm 3	61	11,657	5,146	5,259	30,762
	Bölüm 4	63	11,895	5,988	4,254	32,062
	Bölüm 5	31	12,57	6,53	4,32	32,97
	Bölüm 6	31	11,809	5,325	3,901	27,655

İndeks değerlerinin bölümler arasında farklılık gösterip göstermediğini tespit edebilmek için Kruskal-Wallis Testi uygulanmıştır. Bu amaçla oluşturulan hipotezler şu şekildedir:

- H_0: İndeks değeri ortalamaları bakımından rotanın bölümleri arasında anlamlı bir fark yoktur.
- H_1: İndeks değeri ortalamaları bakımından rotanın bölümleri arasında anlamlı bir fark vardır.

Tüm indeks değeri ortalamaları için p değeri 0,001'den küçük bulunmuştur. Bu sebeple H_0 hipotezi reddedilerek, indeks ortalamaları bakımından rotanın bölümleri arasında anlamlı bir farklılık olduğu söylenebilir.



Şekil 4.5. Rotanın bölümleri için indeks ortalamaları
A) İndeks 1 **B)** İndeks 2 **C)** İndeks 3

Şekil 4.5 incelendiğinde; tüm mental durum indeks değerlerinin sakin hal ölçümlerinde daha düşük, özellikle de gözler kapalı sakin halde en düşük olduğu gözlemlenmektedir. İndeks 1 rotanın bölümleri arasında daha fazla hassasiyet göstermiştir. İndeks 1, İndeks 2 ve İndeks 3'ün ortalama olarak en yüksek değerleri aldığı bölümler sırasıyla Bölüm 5, Bölüm 2 ve Bölüm 5 olmuştur.

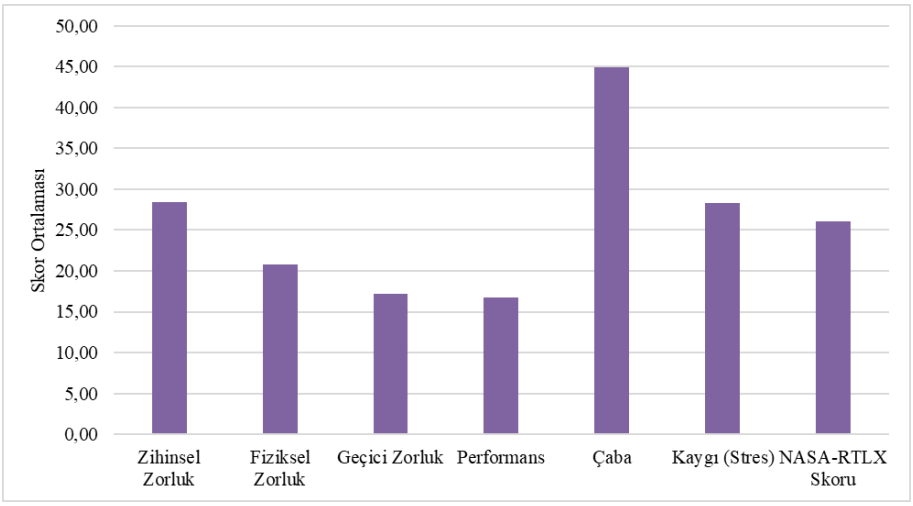
4.3. NASA-RTLX ve Zihinsel Zorluk Skoru Analizi

Tüm katılımcıların sürüş deneyleri sonrasında uygulanan NASA-TLX anketine verdiği cevaplardan yola çıkılarak alt faktörler için ortalama değerler ve ortalama NASA-RTLX skoru 1-100 arasında hesaplanmıştır (Çizelge 4.5).

Çizelge 4.5. NASA-RTLX ve alt faktörlere ait tanımlayıcı istatistikler

Değişken	Örneklem Sayısı	Ortalama	Standart Sapma	Minimum	Maksimum
Zihinsel Zorluk	39	28,46	21,28	5,00	75,00
Fiziksel Zorluk	39	20,77	16,72	5,00	60,00
Geçici Zorluk	39	17,18	18,24	0,00	70,00
Performans	39	16,79	15,24	5,00	70,00
Çaba	39	44,87	32,11	0,00	100,00
Kaygı (Stres)	39	28,33	21,83	5,00	75,00
NASA-RTLX Skoru	39	26,07	15,45	5,00	59,17

Şekil 4.6'daki grafikte görüldüğü üzere, katılımcıların en yüksek puanladıkları alt faktör çaba olmuştur. Bunu zihinsel zorluk ve kaygı alt faktörleri takip etmektedir. Katılımcılarla deney sonrası yapılan görüşmelerde genellikle sürüş deneyi ve EEG cihazı ile ilgili bir miktar stres hissettikleri öğrenilmiştir. NASA-TLX alt faktörlerinden kaygı (stres) skoru ortalamasının 28,33 olduğu görülmektedir. Katılımcılar günlük hayatlarında otomobil süren kişiler olduğundan, sürüş tecrübesi ya da deneyle ilgili stresten bağımsız olmak üzere, otomobil sürme işini zihinsel olarak çok fazla zorlayıcı ve yorucu bulmamaktadırlar. Tüm katılımcılar için ortalaması 28,46 olarak hesaplanan zihinsel zorluk alt faktörü skorunun standart sapması ise 21,28'dir. Aynı zamanda sürüş deneyinde fiziksel ve zamansal açıdan zorlayıcı bir etken bulunmadığından fiziksel zorluk ve geçici zorluk alt faktörleri düşük skorlarla değerlendirilmiştir.

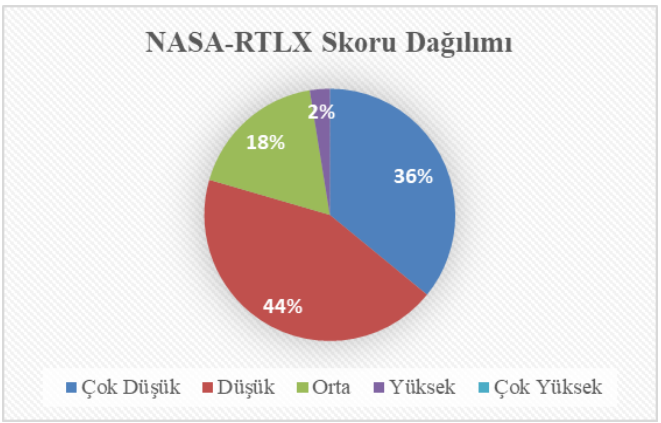


Şekil 4.6. Tüm katılımcılar için NASA-RTLX ve alt faktör skorlarının ortalamaları

NASA-RTLX skorlarının normalitesi aşağıda belirtilen hipotezler kullanılarak Anderson-Darling Normalite Testi ile test edilmiştir. Test sonucunda p değerinin 0,016 olarak bulunması sebebiyle NASA-RTLX skorlarının normal dağılım göstermediği belirlenmiştir.

- H_0: NASA-RTLX skorları normal dağılıma uymaktadır.
- H_1: NASA-RTLX skorları normal dağılıma uymamaktadır.

Katılımcıların NASA-RTLX skorlarına göre iş yükü seviyeleri incelendiğinde Şekil 4.7'deki dağılım ortaya çıkmaktadır. Buna göre otomobil sürme görevi için katılımcıların %36'sının algıladığı iş yükü seviyesinin çok düşük, %44'ünün ise düşük olduğu görülmektedir. Katılımcılardan sadece %20'si orta ve yüksek iş yükü seviyesine sahiptir.

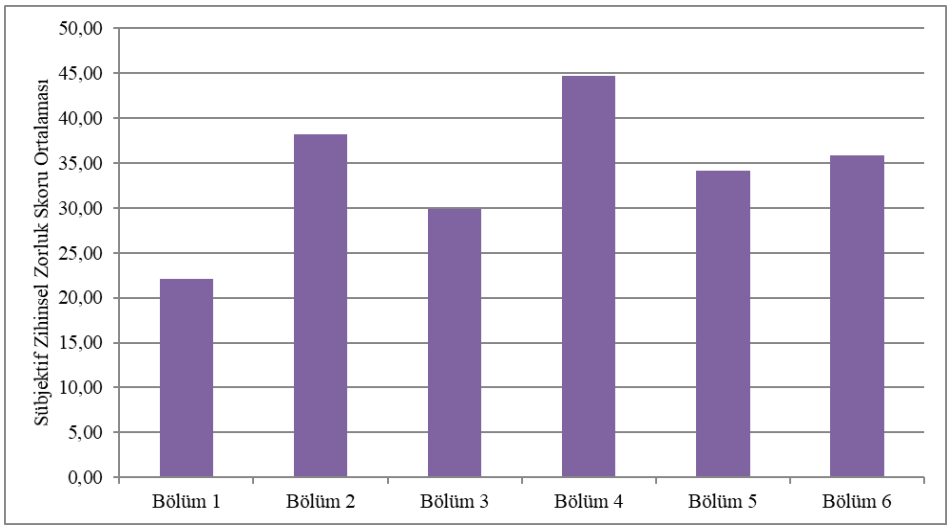


Şekil 4.7. Katılımcıların NASA-RTLX skoruna göre iş yükü seviyeleri

Katılımcıların rotanın bölümlerine göre verdiği sübjektif zihinsel zorluk skorları incelenmiştir (Çizelge 4.6). Zihinsel zorluk skorlarının 5-100 arasında değer aldığı, ortalaması en yüksek olan bölümlerin Bölüm 4 ve Bölüm 2 olduğu görülmüştür (Şekil 4.8). Katılımcılar için zihinsel olarak en zorlayıcı bölüm şehir içi ana yolu temsil eden Bölüm 4 olmuştur. Şehir dışı yolu temsil eden Bölüm 5 ve Bölüm 6'nın katılımcılar için şehir içi ana yola göre daha az zorlayıcı bulunduğu görülmektedir. Bölüm 5 ve 6 arasındaki tek fark ortalama hızdır. Bölüm 6'da daha hızlı bir sürüş gerçekleştirilmektedir. Katılımcılar daha hızlı otomobil sürerken, zihinsel olarak daha fazla zorlandıklarını belirtmektedir. Şehir içi ara yolu temsil eden Bölüm 1 ve 3'ün zihinsel zorluk açısından en düşük olarak puanlandığı görülmektedir. Şehir içi yolu temsil eden bölümler kendi aralarında kıyaslandığında; yaya ve araç trafiğinin en yoğun olduğu Bölüm 2'yi katılımcıların zihinsel olarak daha zorlayıcı bulduğu, yaya ve araç trafiğinin çok az olduğu Bölüm 1'i ise daha az zorlayıcı bulduğu anlaşılmaktadır.

Çizelge 4.6. Sübjektif zihinsel zorluk skorlarına ait tanımlayıcı istatistikler

Zihinsel Zorluk Skoru	Örneklem Sayısı	Ortalama	Standart Sapma	Minimum	Maksimum
Bölüm 1	39	22,05	15,55	5,00	50,00
Bölüm 2	39	38,21	27,52	5,00	100,00
Bölüm 3	39	29,87	22,58	5,00	80,00
Bölüm 4	39	44,62	31,82	5,00	100,00
Bölüm 5	39	34,10	27,95	5,00	100,00
Bölüm 6	39	35,77	24,78	5,00	90,00



Şekil 4.8. Sübjektif zihinsel zorluk skorlarının bölüm bazında ortalamaları

4.4. Trafik ve Yol Koşullarının Mental İş Yükü Üzerindeki Etkisi

Trafik yoğunluğu ve yol tipinin mental durum indeksleri üzerindeki etkisini incelemek için öncelikle rotanın bölümlerinin özellikleri dikkate alınmıştır. Trafik yoğunluğu düşük, orta ve yüksek; yol tipi ise ara yol ve ana yol şeklinde ele alınacaktır. Buna göre düşük trafik yoğunluğuna sahip bölümler Bölüm 1 ve Bölüm 5, orta trafik yoğunluğuna sahip bölümler Bölüm 3 ve Bölüm 6, yüksek trafik yoğunluğuna sahip bölümler Bölüm 2 ve Bölüm 4'tür. Ara yolu temsil eden bölümler Bölüm 1, Bölüm 2 ve Bölüm 3 iken ana yolu temsil eden bölümler ise Bölüm 4, Bölüm 5 ve Bölüm 6'dır. İndeks değerleri ara yolda ana yola göre daha düşüktür. Trafik yoğunluğuna göre indeks değerleri düşük trafik yoğunluğunda en düşüktür ve trafik yoğunluğu arttıkça indeks değerleri artmıştır (Çizelge 4.7).

Farkların istatistiksel anlamlılığını test edebilmek için Kruskal-Wallis Testi uygulanmıştır. Farklı yol tipleri için kurulan hipotezler şu şekildedir:

- H_0: İndeks değeri ortalamaları bakımından farklı yol tipleri (ara yol ve ana yol) arasında anlamlı bir fark yoktur.
- H_1: İndeks değeri ortalamaları bakımından farklı yol tipleri (ara yol ve ana yol) arasında anlamlı bir fark vardır.

Farklı trafik yoğunluğu seviyeleri için kurulan hipotezler şu şekildedir:

- H_0: İndeks değeri ortalamaları bakımından farklı trafik yoğunluğu seviyeleri (düşük, orta, yüksek) arasında anlamlı bir fark yoktur.
- H_1: İndeks değeri ortalamaları bakımından farklı trafik yoğunluğu seviyeleri (düşük, orta, yüksek) arasında anlamlı bir fark vardır.

Tüm testlerde p değerleri 0,05'ten büyük bulunmuştur. Bu sebeple trafik yoğunluğu ve yol tipine göre indeks ortalamaları arasındaki farkın istatistiksel olarak anlamlı olmadığı tespit edilmiştir.

Çizelge 4.7. Trafik yoğunluğu ve yol tipine göre indeks ortalamaları

	Yol Tipi		Trafik Yoğunluğu		
	Ara Yol	**Ana Yol**	**Düşük**	**Orta**	**Yüksek**
İndeks 1	91,520	103,000	87,010	98,000	101,500
İndeks 2	1,179	1,189	1,166	1,177	1,201
İndeks 3	11,377	11,655	11,221	11,334	11,635

4.5. Bireysel Faktörlerin Mental İş Yükü Üzerindeki Etkisi

4.5.1. Cinsiyet

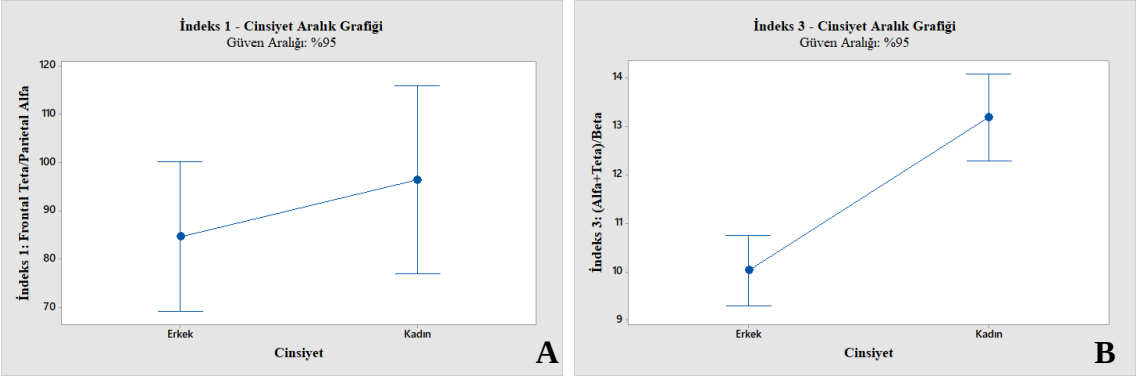
Hesaplanan bant gücü ve indeks değerleri katılımcıların cinsiyeti açısından değerlendirildiğinde, tüm değerlerde kadın katılımcıların ortalamasının erkek katılımcılara göre daha yüksek olduğu görülmüştür. Sinyal kalitesi ortalamaları kadın ve erkek katılımcılar için eşittir. Kadın ve erkek sürücüler arasındaki farklılığın tespiti için aşağıdaki hipotezler kurulmuştur.

- H_0: Bant gücü ve indeks değeri ortalamaları açısından kadın ve erkek sürücüler arasında anlamlı bir fark yoktur.
- H_1: Bant gücü ve indeks değeri ortalamaları açısından kadın ve erkek sürücüler arasında anlamlı bir fark vardır.

Bu hipotezler Kruskal-Wallis Testi ile test edildiğinde alfa bant gücü, teta bant gücü, İndeks 1 ve İndeks 3 ortalamaları arasındaki farkın istatistiksel olarak anlamlı bulunduğu görülmektedir (Çizelge 4.8). Kadın ve erkek sürücüler arasında anlamlı farklılık gösteren indeks değerlerinin değişimi Şekil 4.9'da görülmektedir.

Çizelge 4.8. Bant gücü ve indeks ortalamalarının cinsiyete göre değerlendirilmesi

	Kadın	**Erkek**	**Kruskal-Wallis Testi p değeri**
Sinyal Kalitesi	%90,272	%90,533	0,920
Alfa	3,771	3,041	0,008
Teta	13,170	8,786	0,000
Beta	1,476	1,323	0,191
İndeks 1	96,360	84,620	0,001
İndeks 2	1,257	1,103	0,370
İndeks 3	13,179	10,027	0,000



Şekil 4.9. İndeks ortalamalarının katılımcıların cinsiyetlerine göre değişimi
A) İndeks 1 **B)** İndeks 3

4.5.2. Yaş

Üç farklı yaş grubundaki katılımcıların bant gücü ve indeks değerlerinin ortalamaları hesaplanmıştır. Bant gücü ve indeks değerlerinin farklı yaş grupları arasında gösterdiği farklılığı incelemek üzere aşağıdaki hipotezler oluşturulmuştur:

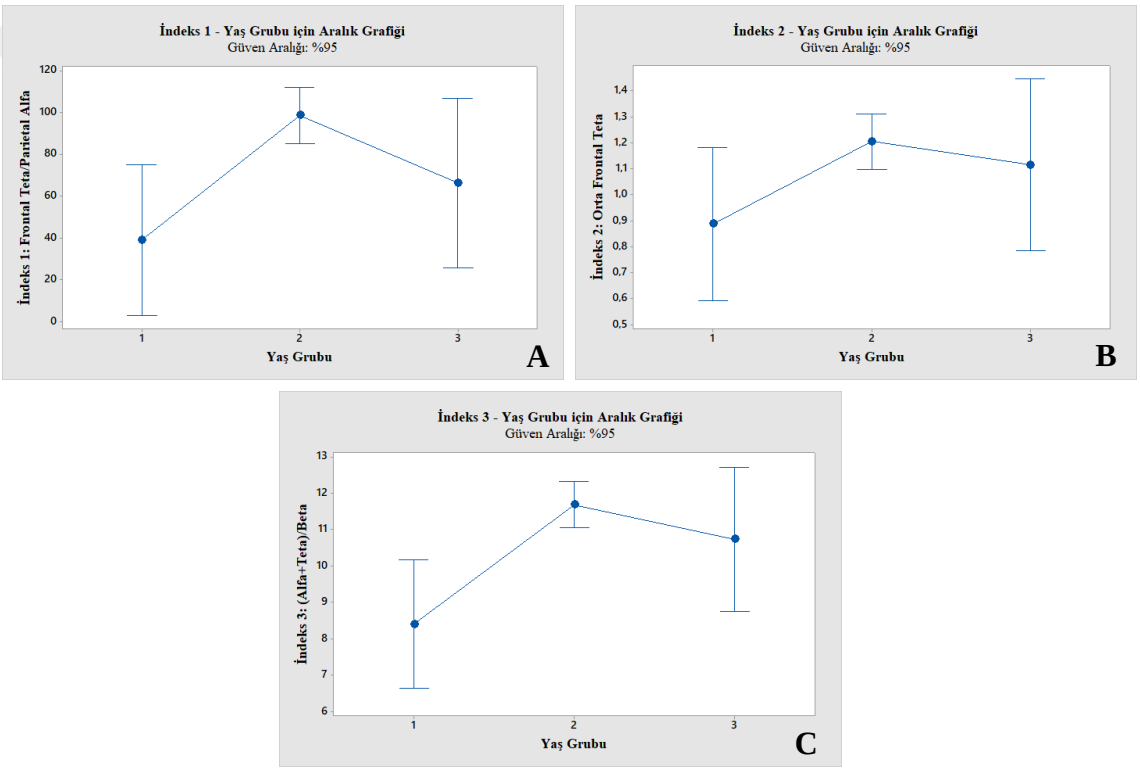
- H_0: Bant gücü ve indeks değeri ortalamaları açısından üç farklı yaş grubundaki sürücüler arasında anlamlı bir fark yoktur.
- H_1: Bant gücü ve indeks değeri ortalamaları açısından üç farklı yaş grubundaki sürücüler arasında anlamlı bir fark vardır.

Bu hipotezler Kruskal-Wallis Testi aracılığıyla incelenmiştir. Buna göre alfa ve teta bant güçleri ile indeks değerlerinin katılımcıların yaş gruplarına göre anlamlı farklılık gösterdiği görülmüştür (Çizelge 4.9).

Çizelge 4.9. Bant gücü ve indeks ortalamalarının yaşa göre değerlendirilmesi

	Grup 1 (18-30 yaş)	**Grup 2 (31-50 yaş)**	**Grup 3 (51 yaş ve üzeri)**	**Kruskal-Wallis Testi p değeri**
Sinyal Kalitesi	%88,130	%90,887	%88,870	0,130
Alfa	3,025	3,431	2,041	0,015
Teta	6,408	11,128	9,730	0,001
Beta	1,315	1,411	1,201	0,415
İndeks 1	39,040	98,550	66,300	0,000
İndeks 2	0,887	1,205	1,116	0,038
İndeks 3	8,406	11,697	10,747	0,003

Anlamlı farklılık gösteren indeksler için farklı yaş grupları arasındaki değişim incelendiğinde, indeks ortalamalarının en düşük 18-30 yaş aralığındaki sürücülerde olduğu görülmektedir. Bununla birlikte indeks değerleri yaşa göre artan bir eğilim izlememektedir (Şekil 4.10). 31-50 yaş aralığındaki sürücülerin sürüş verilerinden elde edilen mental durum indeksleri en yüksek değere sahiptir. Bu durumun sebebi bu yaş aralığındaki katılımcıların sürüş görevi sırasında sadece sürüşe odaklanamayıp, günlük hayattaki diğer işlerini düşünmeleri olabilir. Her ne kadar katılımcılar deney öncesinde çalışmadan ve sakin bir halde gelmiş olsalar da otomobil sürerken bir yandan diğer faktörleri düşünmeleri kaçınılmazdır.



Şekil 4.10. İndeks ortalamalarının katılımcıların yaş gruplarına göre değişimi
A) İndeks 1 **B)** İndeks 2 **C)** İndeks 3

4.5.3. Otomobil sürme tecrübesi

Katılımcıların otomobil sürme tecrübelerinin sürüş esnasındaki mental durumları üzerinde yarattığı etkiyi incelemek amacıyla katılımcılar otomobil sürme tecrübelerine (yıl) göre üç gruba ayrılmıştır. Farklı otomobil sürme tecrübesi grubundaki katılımcıların bant gücü ve indeks değerlerinin ortalaması Çizelge 4.10'da verilmiştir.

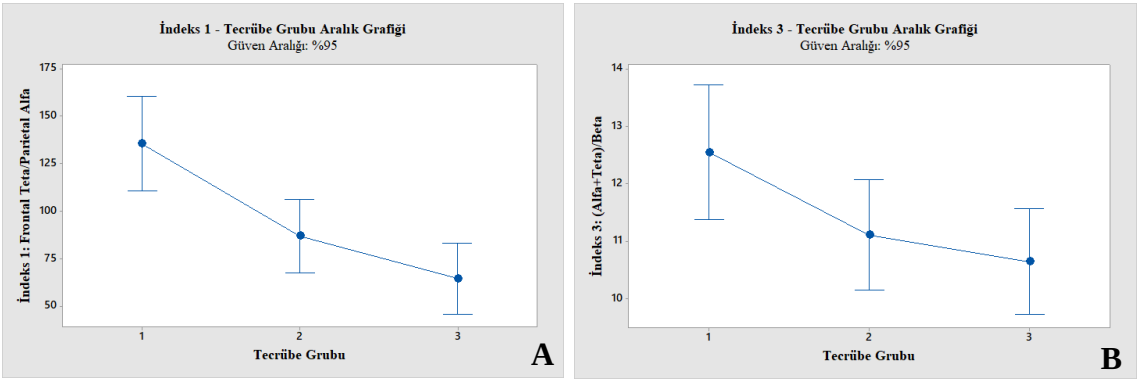
Çizelge 4.10. Bant gücü ve indeks ortalamalarının otomobil sürme tecrübesine göre değerlendirilmesi

	Grup 1 (10 yıldan az)	**Grup 2 (10-20 yıl arası)**	**Grup 3 (20 yıl ve üzeri)**	**Kruskal-Wallis Testi p değeri**
Sinyal Kalitesi	%90,400	%90,724	%90,182	0,792
Alfa	3,513	3,302	3,243	0,329
Teta	10,523	11,660	9,479	0,185
Beta	1,359	1,381	1,401	0,595
İndeks 1	135,600	87,010	64,670	0,001
İndeks 2	1,051	1,223	1,179	0,399
İndeks 3	12,546	11,110	10,646	0,041

Otomobil sürme tecrübesinin etkisini incelemek amacıyla kurulan hipotezler şu şekildedir:

- H_0: Bant gücü ve indeks değeri ortalamaları açısından farklı otomobil sürme tecrübesine sahip sürücüler arasında anlamlı bir fark yoktur.
- H_1: Bant gücü ve indeks değeri ortalamaları açısından farklı otomobil sürme tecrübesine sahip sürücüler arasında anlamlı bir fark vardır.

Gerçekleştirilen Kruskal-Wallis Testi sonucuna göre farklı otomobil sürme tecrübesine sahip sürücülerin İndeks 1 ve İndeks 3 ortalamaları anlamlı farklılık göstermektedir. Şekil 4.11'de anlamlı farklılık gösteren indeksler için karşılaştırma grafikleri görülmektedir. Buna göre, otomobil sürme tecrübesi arttıkça mental iş yükü seviyelerinin azaldığı sonucuna varılmaktadır.



Şekil 4.11. İndeks ortalamalarının katılımcıların otomobil sürme tecrübesine göre değişimi **A)** İndeks 1 **B)** İndeks 3

4.6. Mental İş Yükü Sınıflandırma Sonuçları

Bu bölümde öncelikle tüm katılımcıların verisinin bir arada ele alındığı, iki farklı yaklaşımla etiketlenen iki veri kümesi üzerinde farklı öznitelik seçim yöntemleri ve makine öğrenmesi algoritmalarının uygulanması ile elde edilen katılımcılar-arası sonuçlar sunulmuştur. Daha sonra 39 katılımcının verisinin ayrı ayrı ele alındığı, trafik yoğunluğu ve yol tipine göre etiketlenen veri kümeleri üzerinde sınıflandırma modellerinin uygulanması ile elde edilen katılımcı-bazında sonuçlar verilmiştir.

4.6.1. Katılımcılar-arası mental iş yükü sınıflandırma sonuçları

İlk olarak Veri Kümesi 1 üzerinde ve eğitim-test verisi oranlarının %90-%10 olduğu durumda sınıflandırma modelleri için Grid Arama ile bir parametre optimizasyonu gerçekleştirilmiştir. Böylece modellerin uygulanması aşamasında kullanılacak en uygun parametre değerleri elde edilmiştir. Katılımcılar-arası sınıflandırma modellerinde kullanılan parametrelerin optimal değerleri Çizelge 4.11'de verilmiştir. Her iki veri kümesi için tüm alternatif modeller bu parametreler ile çalıştırılmıştır.

Çizelge 4.11. Katılımcılar-arası sınıflandırma modelleri için optimal parametreler

Model	Parametre	Parametre Değerleri
SVM	Kernel fonksiyonu	Polinomiyal
	Kernel katsayısı (gama)	$1/N$
kNN	Komşu sayısı	5
	Algoritma	Otomatik
	Ağırlık fonksiyonu	Mesafeye bağlı
RO	Ağaç sayısı	200
	Ağaçtaki maksimum seviye sayısı	Sınırsız
	Kriter	Gini impuritesi
YSA	Çözücü	Adam (stokastik gradyan temelli optimizasyon yöntemi)
	Aktivasyon fonksiyonu	Hiperbolik tanjant
	Öğrenme oranı	Sabit (0,001)
	Gizli katman sayısı ve boyutları	(100,)
N: öznitelik sayısı		

Veri Kümesi 1 için eğitim-test verisi oranı %90-%10, %80-%20 ve %70-%30 olduğu durumlarda farklı öznitelik seçim yöntemleri ve makine öğrenmesi modellerinin

uygulanması sonucunda elde edilen doğruluk değerleri Çizelge 4.12'de görülmektedir. Çizelgenin her hücresinde üstteki değer SMOTE yöntemi ile dengelenmiş veri kümesi üzerinde bulunan model performansını, alttaki değer ise beş-katlı çapraz doğrulama ile elde edilen model performansını ifade etmektedir. Veri Kümesi 1 için en iyi sınıflandırma performansını PCA ile öznitelik seçimi yapıldığı durumda RO modeli vermiştir. Eğitim-test verisi oranı %90-%10, %80-%20 ve %70-%30 olduğu durumlar için PCA-RO modelinin doğruluk değerleri sırasıyla %78,62, %78,27 ve %76,84'tür.

Çizelge 4.12. Veri Kümesi 1 için sınıflandırma performansları*

Eğitim-Test Verisi Oranı	Model	Öznitelik Seçimi: Yok	Öznitelik Seçimi: MI	Öznitelik Seçimi: PCA
%90-%10	SVM	54,64 53,88	54,26 53,61	61,62 60,73
	kNN	77,54 76,06	77,19 75,77	77,51 76,31
	RO	78,23 77,19	78,08 76,93	**78,62** 77,21
	YSA	75,48 74,18	74,66 73,03	77,00 75,46
%80-%20	SVM	53,94 53,37	53,71 52,79	61,32 60,07
	kNN	76,05 75,57	75,92 75,32	76,56 75,70
	RO	78,22 76,09	77,75 76,15	**78,27** 76,61
	YSA	74,61 73,66	73,39 72,80	75,16 75,01
%70-%30	SVM	54,13 53,08	57,42 56,97	58,67 58,46
	kNN	75,82 75,05	75,45 74,63	75,36 74,76
	RO	76,73 75,92	75,82 75,45	**76,84** 75,84
	YSA	74,37 73,68	73,35 72,54	73,36 72,83

** Hücrelerde üstteki değer dengelenmiş veri kümesi üzerinde bulunan model performansını, alttaki değer beş-katlı çapraz doğrulama ile elde edilen model performansını ifade etmektedir.*

Sınıflandırma performansları incelendiğinde PCA ile öznitelik seçimi yapıldığı durumda en yüksek doğruluk değerlerine ulaşıldığı görülmektedir. Öznitelik seçimi alternatifleri arasındaki farklar Mann-Whitney U Testi ile incelenmiştir. İncelenen hipotezler şu şekildedir:

- H_0: Modellerin doğruluk değeri açısından öznitelik seçim alternatifleri arasında anlamlı bir fark yoktur.
- H_1: Modellerin doğruluk değeri açısından öznitelik seçim alternatifleri arasında anlamlı bir fark vardır.

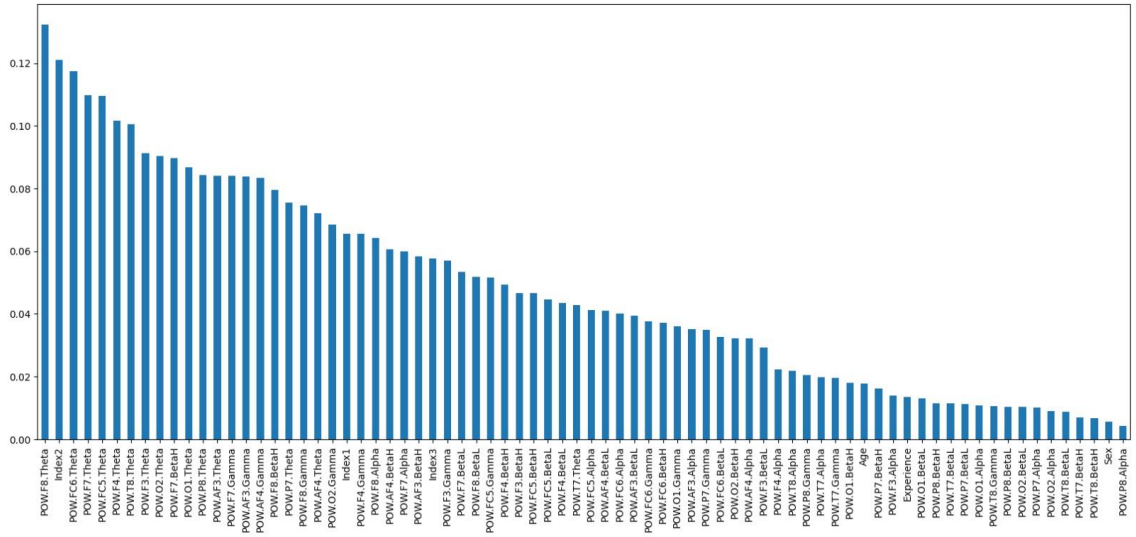
Öznitelik seçimi yapılmadığı durum ile MI ve PCA arasındaki p değerleri sırasıyla 0,644 ve 0,624 bulunmuştur. MI ve PCA arasındaki fark için hesaplanan p değeri ise 0,436'dır. Buna göre öznitelik seçim alternatifleri arasındaki istatistiksel olarak anlamlı fark olmadığı tespit edilmiştir. Bu durum MI ve PCA ile Veri Kümesi 1 için seçilen öznitelik sayılarına bakılırsa daha net anlaşılabilir (Çizelge 4.13). En iyi sonucun bulunduğu %90-%10 eğitim-test verisi oranı için PCA ile seçilen öznitelik sayısı 50'dir.

Çizelge 4.13. Veri Kümesi 1 için MI ve PCA ile seçilen öznitelik sayıları

Eğitim-Test Verisi Oranı	Seçilen Öznitelik Sayısı	
	MI	PCA
%90-%10	70	50
%80-%20	70	40
%70-%30	70	20

Şekil 4.12'de Veri Kümesi 1 için MI ile hesaplanan özniteliklerin önem sıralamasının grafiği görülmektedir. Buna göre mental iş yükü sınıflandırmasında en etkili bulunan özniteliklerin F8, FC6, F7, FC5 ve F4 elektrotlarındaki teta bant güçleri ve İndeks 2 olduğu görülmektedir. İndeks 2 orta frontal bölgedeki yani F3 ve F4 kanallarındaki teta bant güçlerinin ortalamasını ifade ettiğinden, karşılıklı bilgiye göre en önemli özniteliklerin frontal bölgedeki teta bant güçleri olduğu söylenebilir.

Veri Kümesi 2 için eğitim-test verisi oranı %90-%10, %80-%20 ve %70-%30 olduğu durumlarda farklı öznitelik seçim yöntemleri ve makine öğrenmesi modellerinin uygulanması sonucunda elde edilen doğruluk değerleri Çizelge 4.14'te görülmektedir. Veri Kümesi 2 için en iyi sınıflandırma performansını öznitelik seçimi yapılmadığı durumda RO modeli vermiştir. Eğitim-test verisi oranı %90-%10, %80-%20 ve %70-%30 olduğu durumlar için en yüksek doğruluk değerleri sırasıyla %86,24, %85,76 ve %85,36'dır.



Şekil 4.12. Veri Kümesi 1 için MI öznitelik önem sırası

Çizelge 4.14. Veri Kümesi 2 için sınıflandırma performansları*

Eğitim-Test Verisi Oranı	Model	Öznitelik Seçimi: Yok	Öznitelik Seçimi: MI	Öznitelik Seçimi: PCA
%90-%10	SVM	59,24 58,40	63,40 63,22	68,15 66,85
	kNN	83,43 82,68	83,64 82,16	84,54 83,03
	RO	**86,24** 84,46	85,82 83,90	86,23 84,37
	YSA	84,08 81,55	85,24 83,33	85,43 84,41
%80-%20	SVM	58,89 58,37	58,50 57,99	68,27 67,58
	kNN	83,44 82,48	83,39 82,33	84,07 83,14
	RO	85,33 83,84	85,28 83,76	85,12 83,66
	YSA	83,24 81,70	83,68 83,43	**85,76** 84,90
%70-%30	SVM	57,71 57,65	62,63 62,50	67,96 67,59
	kNN	82,22 82,14	81,93 81,66	82,68 82,64
	RO	83,97 83,35	83,47 82,88	83,71 82,82
	YSA	83,78 83,87	83,20 82,25	85,12 **85,36**

** Hücrelerde üstteki değer dengelenmiş veri kümesi üzerinde bulunan model performansını, alttaki değer beş-katlı çapraz doğrulama ile elde edilen model performansını ifade etmektedir.*

Modellerin sınıflandırma performansları arasındaki farklılık %95 güven düzeyinde Kruskal-Wallis Testi ile test edilmiştir. Hipotezler şu şekilde kurulmuştur:

- H_0: Doğruluk değeri açısından katılımcılar arası zihinsel iş yükü sınıflandırma modelleri arasında anlamlı bir fark yoktur.
- H_1: Doğruluk değeri açısından katılımcılar arası zihinsel iş yükü sınıflandırma modelleri arasında anlamlı bir fark vardır.

Test sonucunda Veri Kümesi 1 ve Veri Kümesi 2 için p değerleri sırasıyla 0,016 ve 0,019 olarak bulunmuştur. Her iki veri kümesi için zihinsel iş yükü sınıflandırma modellerinin performansları arasında anlamlı bir fark olduğu tespit edilmiştir. Farkın hangi modeller arasında oluştuğunu belirlemek için uygulanan Mann-Whitney U Testi sonucunda elde edilen p değerleri Çizelge 4.15'te verilmiştir. Buna göre; Veri Kümesi 1 için RO-kNN çifti dışındaki modellerin performansı arasındaki farklar istatistiksel olarak anlamlı, Veri Kümesi 2 için ise RO-YSA ve kNN-YSA çiftleri dışındaki modellerin performansı arasındaki farklar istatistiksel olarak anlamlı bulunmuştur.

Çizelge 4.15. Katılımcılar-arası sınıflandırma modellerinin performansları arasındaki farkların tespiti için Mann-Whitney U Testi ile elde edilen p değerleri

	Model	SVM	kNN	YSA
Veri Kümesi 1	RO	0,005	0,109	0,008
	SVM		0,005	0,005
	kNN			0,020
Veri Kümesi 2	RO	0,005	0,020	0,173
	SVM		0,005	0,005
	kNN			0,298

Çizelge 4.16'da Veri Kümesi 2 için MI ve PCA ile seçilen öznitelik sayıları verilmiştir. En iyi sonucun bulunduğu %90-%10 eğitim-test verisi oranı için MI ile 70 öznitelik seçilmiş, diğer bir deyişle öznitelik seçimi yapılmaması daha iyi sonuç vermiştir. PCA ile ise eğitim-test verisi oranı %90-%10, %80-%20 ve %70-%30 olduğu durumlar için sırasıyla 30, 40 ve 20 adet öznitelik çıkarılmıştır. Eğitim-test verisi oranı %80-%20 ve %70-%30 olduğu durumlarda en iyi performansı PCA-YSA modelinin verdiği

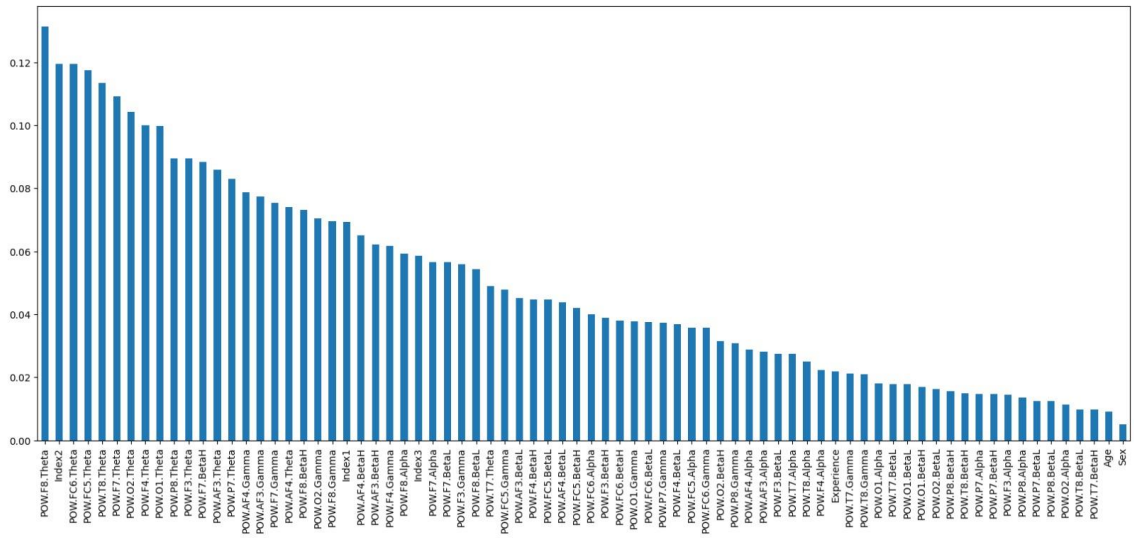
düşünülürse, PCA ile çıkarılan özniteliklerin YSA modelinin iyi sonuç vermesinde etkili olduğu söylenebilir.

Veri Kümesi 2 için öznitelik seçimi alternatiflerinin performansları arasındaki farklar Mann-Whitney U Testi ile incelenmiştir. Öznitelik seçimi yapılmadığı durum ile MI ve PCA arasındaki p değerleri sırasıyla 0,977 ve 0,260, ve MI ve PCA arasındaki p değeri 0,260 olarak hesaplanmıştır. Buna göre Veri Kümesi 2 için de öznitelik seçim alternatifleri arasında istatistiksel olarak anlamlı bir fark bulunmamaktadır.

Çizelge 4.16. Veri Kümesi 2 için MI ve PCA ile seçilen öznitelik sayıları

Eğitim-Test Verisi Oranı	Seçilen Öznitelik Sayısı	
	MI	PCA
%90-%10	70	30
%80-%20	70	40
%70-%30	70	20

Şekil 4.13'te Veri Kümesi 2 için MI ile hesaplanan özniteliklerin önem sıralamasının grafiği görülmektedir. Yol tipine göre mental iş yükü sınıflandırması için en etkili bulunan öznitelikler F8, FC6, FC5, T8 ve F7 elektrotlarındaki teta bant güçleri ve İndeks 2 olmuştur. Bireysel faktörlerin mental iş yükünü sınıflandırırken etkili öznitelikler arasında bulunmadığı, diğer bir deyişle farklı özniteliklere göre daha önemli bulunmadıkları tespit edilmiştir.



Şekil 4.13. Veri Kümesi 2 için MI öznitelik önem sırası

4.6.2. Katılımcı-bazında mental iş yükü sınıflandırma sonuçları

Katılımcı-bazında mental iş yükü sınıflandırma performanslarının hem trafik yoğunluğu hem de yol tipine göre belirlenmesi için tez çalışmasında kullanılan etiketleme yaklaşımıyla 39 katılımcının her biri için ikişer adet veri kümesi oluşturulmuştur. Her katılımcının verisi üzerinde, ilk olarak katılımcılar-arası sınıflandırmada olduğu gibi eğitim-test verisi oranı %90-%10 alınarak Grid Arama yöntemi ile en iyi model parametresi değerleri belirlenmiş ve tüm modeller bu parametreler ile çalıştırılmıştır.

Her katılımcının trafik yoğunluğu ve yol tipine göre etiketlenmiş iki veri kümesi için kullanılan en iyi model parametresi değerleri sırasıyla EK 3 ve EK 4'teki çizelgelerde verilmiştir. RO modelleri için ormandaki ağaç sayısı 100, 200, 300 ve 500 arasında değişkenlik göstermiştir. Kriter olarak Gini impuritesi veya Shannon entropisi kullanılırken, bir ağaçtaki maksimum seviye sayısı tüm modeller için sınırsız olarak tercih edilmiştir. SVM modellerinde Kernel katsayısı $1/N$ olarak seçilmiş, Kernel fonksiyonu ise lineer, polinomiyal veya radyal temelli fonksiyon olarak değişmiştir. KNN modellerinin tamamında algoritma otomatik olarak seçilirken, komşu sayısı 3-35 arasında değişmiştir. Ağırlık fonksiyonu düzgün veya mesafeye bağlı olarak değişmiştir. YSA modellerinin neredeyse tamamında çözücü olarak Adam kullanılmış, çoğunda ise aktivasyon fonksiyonu olarak hiperbolik tanjant ve ReLU seçilmiştir. Gizli katman sayıları bir veya iki, gizli katmandaki nöron sayısı ise genellikle yüz olarak seçilmiştir.

Katılımcı-bazında gerçekleştirilen sınıflandırma için eğitim-test verisi oranı %90-%10 olarak seçilmiştir. Elde edilen doğruluk değerleri trafik yoğunluğuna göre etiketlenen veri kümeleri için EK 5'te, yol tipine göre etiketlenen veri kümeleri için EK 6'da sunulmuştur. Çizelge 4.17'de tüm katılımcıların verisi üzerinde elde edilen model performanslarının minimum, ortalama ve maksimum değerleri özetlenmiştir. Buna göre trafik yoğunluğuna göre etiketlenen veri kümeleri için katılımcı-bazında en iyi performansı öznitelik seçimi olmadan YSA modeli vermiş, en yüksek %96,51 doğruluğa ulaşılmıştır. Yol tipine göre etiketlenen veri kümeleri için katılımcı-bazında en iyi performansı YSA-PCA modeli vermiş, en yüksek %98,06 doğruluğa ulaşılmıştır.

Çizelge 4.17. Katılımcı-bazında sınıflandırma performanslarının minimum, ortalama ve maksimum değerleri*

Veri Kümesi	Model	Öznitelik Seçimi: Yok	Öznitelik Seçimi: MI	Öznitelik Seçimi: PCA
1	SVM	72,46 80,44 91,28	70,52 79,83 93,02	69,08 79,13 91,28
	kNN	65,35 75,21 88,02	65,35 75,85 88,95	65,35 75,78 88,30
	RO	73,24 81,95 92,44	**74,20** **82,81** 93,60	71,96 81,17 92,44
	YSA	71,96 81,46 **96,51**	70,59 80,79 94,77	70,09 81,59 93,60
2	SVM	74,09 88,92 97,40	74,09 87,98 97,14	74,09 86,99 97,09
	kNN	70,57 80,58 92,26	71,01 82,23 94,28	72,22 81,47 92,86
	RO	80,16 89,32 97,19	82,58 89,81 98,05	82,54 88,86 96,51
	YSA	80,31 89,76 97,57	79,77 89,08 97,57	**82,74** **89,86** **98,06**

** Hücrelerde üstteki değer doğruluk değerlerinin minimumunu, ortadaki değer ortalamasını, alttaki değer ise maksimumunu ifade etmektedir.*

Katılımcı-bazında sınıflandırma modellerinin performansları arasındaki farklılık, modellerin ortalama doğruluk değerleri dikkate alınarak, %95 güven düzeyinde Kruskal-Wallis Testi ile test edilmiştir. Hipotezler şu şekildedir:

- H_0: Doğruluk değeri açısından katılımcı-bazında zihinsel iş yükü sınıflandırma modelleri arasında anlamlı bir fark yoktur.
- H_1: Doğruluk değeri açısından katılımcı-bazında zihinsel iş yükü sınıflandırma modelleri arasında anlamlı bir fark vardır.

Test sonucunda Veri Kümesi 1 ve Veri Kümesi 2 için p değerleri sırasıyla 0,022 ve 0,031 olarak bulunmuştur. Buna göre her iki veri kümesi için katılımcı-bazında zihinsel iş yükü sınıflandırma modellerinin ortalama doğruluk değerleri arasında anlamlı bir fark olduğu söylenebilir. Farklılığın hangi modeller arasında oluştuğunu belirlemek için

uygulanan Mann-Whitney U Testi sonucunda elde edilen p değerleri Çizelge 4.18'de verilmiştir. Buna göre her iki veri kümesi için modellerin doğruluk değeri ortalamaları arasındaki farkların istatistiksel olarak anlamlı olmadığı tespit edilmiştir.

Çizelge 4.18. Katılımcı-bazında sınıflandırma modellerinin performansları arasındaki farkların tespiti için Mann-Whitney U Testi ile elde edilen p değerleri

	Model	SVM	kNN	YSA
Veri Kümesi 1	RO	0,081	0,081	0,383
	SVM		0,081	0,081
	kNN			0,081
Veri Kümesi 2	RO	0,190	0,081	0,663
	SVM		0,081	0,081
	kNN			0,081

Katılımcı-bazında zihinsel iş yükü sınıflandırma modellerinde MI ile seçilen özniteliklerin önem sırası incelenmiştir. Katılımcılar arası sınıflandırmadan farklı olarak, katılımcı-bazında sınıflandırmada karşılıklı bilgiye göre en önemli özniteliklerin sadece frontal bölgedeki teta bant güçlerini içermediği, kişiye göre değişkenlik gösterdiği saptanmıştır. Örneğin bir sürücünün modelinde en önemli bulunan öznitelikler frontal ve temporal bölge elektrotlarındaki gama bant güçleri olurken, bir başka sürücünün modelinde frontal teta ve oksipital alfa bant güçleri olabilmektedir.

Katılımcı-bazında sınıflandırmada her katılımcının modeli için seçilen en iyi beş öznitelik dikkate alınarak bir değerlendirme yapılmıştır. Çizelge 4.19'da verilen değerlendirme sonucuna göre, gama bant güçlerinin trafik yoğunluğuna göre etiketlenen Veri Kümeleri 1 için en önemli bulunan özniteliklerin %45'ini, yol tipine göre etiketlenen Veri Kümeleri 2 için en önemli bulunan özniteliklerin %42'sini oluşturduğu belirlenmiştir. Beyin bölgeleri açısından bakıldığında ise, çoğunlukla frontal bölge elektrotları ön plana çıkmıştır. Veri Kümeleri 1 için en önemli bulunan özniteliklerin %47'sini, yol tipine göre etiketlenen Veri Kümeleri 2 için en önemli bulunan özniteliklerin %44'ünü frontal bölge elektrotlarındaki bant gücü değerlerinin oluşturduğu görülmüştür.

Çizelge 4.19. Katılımcı-bazında sınıflandırma modellerinde MI önem sırasına göre en önemli bulunan özniteliklerin dağılımı

Öznitelikler		**Veri Kümesi 1**	**Veri Kümesi 2**
Bant gücü ve indeksler	Gama	81 (%45)	75 (%42)
	Teta	56 (%31)	68 (%38)
	Yüksek Beta	23 (%13)	23 (%13)
	Düşük Beta	4 (%2)	3 (%2)
	Alfa	6 (%3)	4 (%2)
	İndeks 1	5 (%3)	4 (%2)
	İndeks 2	3 (%2)	1 (%1)
	İndeks 3	2 (%1)	2 (%1)
Beyin bölgeleri	Frontal	80 (%47)	76 (%44)
	Parietal	30 (%18)	31 (%18)
	Temporal	33 (%19)	33 (%19)
	Oksipital	27 (%16)	33 (%19)

5. TARTIŞMA VE SONUÇ

Kişilerin günlük yaşamında ulaşım amaçlı gerçekleştirdikleri başlıca işlerden bir tanesi otomobil sürme işidir. Ülkemizde ve dünyada nüfusun artmasıyla trafikteki araç sayısı da her geçen gün artmaktadır. Bu durum beraberinde trafik ve yol güvenliğinin sağlanması ile ilgili yapılması gereken çalışmalar ve alınması gereken önlemleri daha da önemli hale getirmektedir. Dünyada her yıl trafik kazaları nedeniyle yaklaşık 1,19 milyon insan hayatını kaybetmektedir. Yirmi milyondan fazla insan ise trafik kazası sonucu yaralanmalara maruz kalmakta, birçoğu engelli olma durumuyla karşı karşıya gelmektedir. Ölüm, yaralanma ve sakatlanmaların yanı sıra trafik kazaları bireylere, ailelerine ve bir bütün olarak yaşadıkları ülkeye önemli ekonomik kayıplar getirmektedir. Karayolu trafik kazaları çoğu ülkede gayri safi yurt içi hasılanın %3'üne mal olmaktadır (Dünya Sağlık Örgütü, 2023). Trafik kazalarının büyük bir çoğunluğunun sürücü hatalarından kaynaklandığı bilinmektedir. Bu sebeple sürücülerin fiziksel ve zihinsel olarak otomobil sürme görevini güvenli bir şekilde tamamlamasını sağlamak büyük önem arz etmektedir.

Otomobil sürücülerinin zihinsel durumunun trafik ve yol güvenliği açısından önemli olmasının çeşitli nedenleri vardır. Karar verme süreçleri açısından bakıldığında, sürücünün hızlı ve sağlıklı karar verme yeteneği zihinsel durumundan doğrudan etkilenmektedir. Sürücü eğer stresli veya yorgun ise ya da dikkati dağılmışsa, karar verme konusunda problem yaşayabilir. Sürücünün uyanıklık, odaklanma ve zihinsel durumu tepki süresinde de önemli rol oynamaktadır. Trafikte ani duruşlar, yaya geçitleri veya diğer araçların manevraları gibi beklenmedik olaylara tepki vermek için hızlı karar vermek ve kararı hızlı uygulamak gereklidir. Anlık bir dikkat dağınıklığı kaza riskini arttırmaktadır. Bir sürücünün durumsal farkındalığını koruyabilmesi yoldaki potansiyel tehlikeleri önceden tahmin etmesini, fark etmesini ve bunlardan kaçınabilmesini sağlar. Zihinsel yorgunluk da dikkat dağınıklığına, tepki sürelerinin artmasına ve karar verme süreçlerinin bozulmasına sebep olabilir. Bu sebeplerle bir otomobil sürücüsünün algılama, hafıza ve muhakeme gibi bilişsel işlevlerinde oluşan bozulmalar, sürüş görevinin güvenli bir şekilde tamamlanmasını engelleyebilir. Sonuç olarak, sürücülerin

zihinsel durumunun incelenmesi ve takip edilmesi için gerekli çalışmaların yapılması trafik ve yol güvenliğinin sağlanmasında kritik bir faktördür.

Bu tez çalışmasında, otomobil sürücülerinin farklı trafik ve yol koşullarındaki zihinsel iş yüklerinin incelenmesi amaçlanmıştır. EEG sinyallerinin ve NASA-TLX yönteminin kullanılmasıyla, iş yükü ölçümünde hem objektif hem de sübjektif yöntemlerden faydalanarak farklı sürüş koşulları sırasında sürücülerin zihinsel durumlarının kapsamlı bir şekilde anlaşılması hedeflenmiştir. Çalışmadaki temel hedeflerden bir tanesi literatürdeki çalışmaların çoğundan farklı olarak sürüş deneylerini tamamen gerçek trafik ortamında gerçekleştirmek olmuştur. Ayrıca gerçek sürüşteki EEG verileri ile birlikte sürücülerin bireysel özelliklerini de dikkate alarak, zihinsel iş yükünün sınıflandırılması için makine öğrenmesi modellerinin kullanımının araştırılması çalışmanın bir diğer temel amacıdır. Bu amaçla gerçekleştirilen katılımcılar-arası ve katılımcı-bazında sınıflandırma sonuçlarının analiziyle sürücülerin zihinsel iş yükünü tahmin etme konusunda hem genel bir sonuca hem de bireysel farklılıkları da dikkate alan sonuçlara ulaşılması hedeflenmiştir.

Çalışmada öncelikle 39 gönüllü sürücünün katılımıyla gerçek trafik ortamında daha önceden belirlenen bir rota üzerinde sürüş deneyleri gerçekleştirilmiştir. Sürücülerin zihinsel iş yükü EEG ve NASA-TLX yöntemleri kullanılarak ölçülmüştür. EEG sinyallerinden alfa, teta ve beta bant güçlerinin yanı sıra, zihinsel iş yükünü ve zihinsel yorgunluğu temsil eden üç mental durum indeksi hesaplanmıştır. Bant gücü ve indeks değeri ortalamaları rotanın farklı trafik yoğunluğu ve yol koşuluna sahip farklı bölümleri için incelenmiştir. Katılımcıların zihinsel iş yükünün cinsiyet, yaş ve otomobil sürme tecrübesi gibi kişisel faktörlere göre değişimi de istatistiksel olarak analiz edilmiştir. Daha sonra zihinsel iş yükünün trafik yoğunluğu ve yol tipine göre etiketlendiği iki veri kümesi oluşturulmuş ve dengeli hale gelmesi sağlanmıştır. Veri kümeleri üzerinde üç iş yükü sınıfını tahmin etmek amacıyla makine öğrenmesi modelleri uygulanmıştır. MI ve PCA ile gerçekleştirilen öznitelik çıkarım aşamasının ardından SVM, kNN, RO ve YSA modelleri ile katılımcılar-arası ve katılımcı-bazında sınıflandırmalar gerçekleştirilmiştir.

Gerçek trafikte kaydedilen EEG sinyallerinden hesaplanan alfa, teta, beta bant güçleri ve mental durum indeksleri sakin hal ve aktif sürüş görevi arasında anlamlı farklılık göstermiştir. İndeks değerleri yol tipine göre incelendiğinde, ana yollarda ara yola göre daha fazla zihinsel iş yükü oluştuğu görülmüştür. Trafik koşulları açısından incelendiğinde ise, trafik yoğunluğu arttıkça zihinsel iş yükünün arttığı görülmüştür. Rotanın bölümleri arasında en hassas değişkenliği İndeks 1 göstermiştir. Bu durum İndeks 1 yani Frontal Teta/Parietal Alfa oranının diğer mental durum indekslerine göre en iyi performansı gösteren indeksler arasında olduğu sonuçları (Holm vd., 2009) doğrulayıcı niteliktedir.

NASA-RTLX skorlarına göre sürüş görevi sırasında sürücülerin %80'inin çok düşük ve düşük iş yükü algıladıkları tespit edilmiştir. NASA-RTLX'in rotanın her bölümü sonrasında uygulanamaması sebebiyle skorlar bölümlere göre incelenmemiştir. Ancak her deney sonrasında sürücülerden rotanın bölümleri için alınan zihinsel zorluk skorları incelendiğinde, en yüksek sübjektif zihinsel zorluk skoru ortalamasının Bölüm 4 ve Bölüm 2'de ortaya çıktığı görülmüştür. Buna göre katılımcıların trafik yoğunluğunun yüksek olduğu bölümlerde daha fazla zihinsel iş yüküne maruz kaldıkları söylenebilir.

Sürücülerin sürüş görevi sırasındaki yaşadıkları zihinsel zorlanma bireysel özelliklerine göre farklılık gösterebilir. Bu hipotezi araştırmak amacıyla üç bireysel özellik ile sürücülerin zihinsel iş yükleri arasındaki ilişki istatistiksel olarak incelenmiştir. Ele alınan bireysel özellikler sürücünün yaşı, cinsiyeti ve yıl bazında otomobil sürme tecrübesidir. Yaşın etkisi incelendiğinde, otuz yaş altındaki genç sürücülerin diğer yaş gruplarındaki sürücülere göre daha az zihinsel iş yüküne maruz kaldıkları tespit edilmiştir. Ancak bu çalışmadaki katılımcılar için sürücünün yaşı arttıkça zihinsel iş yükü artmamıştır. En yüksek zihinsel iş yükünün 31-50 yaş grubundaki katılımcılarda oluştuğu görülmüştür. Bunun sebebi bu yaş aralığındaki katılımcıların kendilerini günlük hayattaki aktivitelerden tam olarak soyutlayamaması olabilir. Her ne kadar deneye gönüllü olarak katılım gösteren sürücülerin sabah saatlerinde, çalışmadan ve yorulmadan gelmesine özen gösterilse de günün devamında yapılacak olan işlerin katılımcıların zihinsel iş yükünü etkilemiş olması mümkündür. 31-50 yaş aralığındaki katılımcıların oranı %79'dur. Otuz yaş altı ve elli yaş üstü sürücülerden sayıca daha az

kişi katılım gösterebilmiştir. Dolayısıyla yaşa göre zihinsel iş yükünün belirli bir eğilime sahip olmamasının diğer bir nedeni de katılımcıların yaş gruplarındaki dağılımının homojen olmaması olabilir.

Cinsiyete dayalı zihinsel yük incelemesi sonucunda kadın sürücülerin erkek sürücülere kıyasla göreceli olarak daha yüksek zihinsel iş yükü sergiledikleri belirlenmiştir. Kadın ve erkek katılımcıların yıl ve mesafe bazında otomobil sürme tecrübeleri ayrı ayrı incelendiğinde; otomobil sürme tecrübesi kadın katılımcılarda ortalama 14,81 yıl, erkek katılımcılarda ortalama 17,83 yıl olarak hesaplanmıştır. Ayrıca kadın katılımcıların yıllık ortalama otomobil sürme mesafeleri 14593 km iken aynı değer erkek katılımcılar için ortalama 26217 km olarak bulunmuştur. Bu değerlerden yola çıkılarak, bu çalışmadaki sürüş görevine katılan erkek sürücülerin kadın sürücülere göre otomobil sürme açısından daha tecrübeli olması sebebiyle zihinsel iş yükü seviyeleri üzerinde bu şekilde bir etkinin oluştuğu söylenebilir. Cinsiyete göre net bir ayrımın yapılabilmesi için daha fazla katılımcı ile deney yapılması gerekmektedir.

Farklı otomobil sürme tecrübesine sahip katılımcı gruplarının mental durum indeks ortalamaları arasındaki farklar incelendiğinde, otomobil sürme tecrübesinin zihinsel iş yükü üzerinde etkili olduğu görülmüştür. Yirmi yıldan uzun süredir otomobil kullanan sürücülerin daha az tecrübeli sürücülere göre düşük zihinsel iş yükü gösterdiği tespit edilmiştir. Katılımcıların otomobil sürme tecrübesi kaç yıldır aktif otomobil kullandığına göre belirlenmiştir. Bununla birlikte günlük hayatta kullandığı ve deneye katıldığı şahsi otomobilini ne kadar süredir kullandığı ile ilgili bir inceleme yapılmamıştır. Sürücünün kullandığı otomobile olan alışkanlığı, sürüş rotasına olan aşinalığı gibi durumlar da zihinsel durumu etkileyebileceğinden gelecek çalışmalarda dikkate alınabilir.

Bu tez çalışmasının deneysel prosedür açısından birkaç kısıtlılığı mevcuttur. Bunlardan ilki, gerçek trafikteki sürüş deneylerinin sürücülerin şahsi otomobilleri ile gerçekleştirilmesidir. Burada amaç katılımcının alışkın olduğu otomobili sürerken beyin aktivitesinin kaydedilmesini sağlamaktır. Bu durumda sürüş deneyindeki otomobilin tipi üzerinde kesin bir kontrol sağlanamamıştır. Otomobiller arasındaki farklılığın kontrolü

için tüm katılımcıların aynı araçla sürüş görevini gerçekleştirmesi mümkün olabilirdi. Ancak bunun için aynı sürüş rotasında birden fazla sayıda otomobile ve rotaya alışma turu yapılması gerekirdi. Zaman ve maddi kaynak kısıtları açısından alışma turu yapılmamıştır. Çalışmanın bir diğer kısıtlılığı gönüllü katılımcıların sayısıdır. Çeşitli yaş ve meslek grubundan katılımcıların en az bir saatini ayırmaları gereken sürüş görevlerine katılmak için zaman yaratmaları ve kendi araçlarıyla yapılacak sürüş için maddi kaynak ayırmaları gerektiğinden katılımcı sayısı daha fazla arttırılamamıştır.

Bu tez çalışmasında sürücülerin gerçek sürüş görevi sırasında kaydedilen EEG sinyallerinin ve sübjektif değerlendirmelerinin istatistiksel olarak analiz edilmesinin yanı sıra zihinsel iş yükünü sınıflandırmak için makine öğrenmesi modellerinin kullanımı da araştırılmıştır. Zihinsel iş yükünü EEG bant güçleri, EEG tabanlı mental durum indeksleri ve yaş, cinsiyet, otomobil sürme tecrübesi gibi bireysel faktörlere göre sınıflandırmak için makine öğrenmesi modelleri ile dikkate değer bulgular elde edilmiştir. Katılımcılar-arası sınıflandırmada trafik yoğunluğuna göre etiketlenen Veri Kümesi 1 üzerinde %78,62 doğruluk değeri ile en yüksek performansı PCA ile öznitelik çıkarımı ve RO modeli vermiştir. Yol tipine göre etiketlenen Veri Kümesi 2 üzerinde de %86,24 doğruluk değeri ile en yüksek performansı öznitelik çıkarımı olmadan RO modeli vermiştir.

Literatürde iş yükünü tahmin eden benzer çalışmalarda SVM modelinin ön plana çıktığı görülürken (Aygun vd., 2022; Becerra-Sánchez vd., 2020; Islam vd., 2019), bu çalışmada SVM modeli diğerlerinin gerisinde kalmıştır. Bu çalışmadaki katılımcılar-arası sınıflandırmada en iyi performansı gösteren RO algoritması, büyük veri kümeleri için aşırı uyum sorununu önlemesi, mevcut öznitelikler arasından en önemli öznitelikleri tanımlayabilmesi ve güçlü parametreler içermesi sebebiyle tercih edilmektedir. Burada RO modelinin ulaştığı sınıflandırma performansı gerçek trafik ortamında zihinsel iş yükünü doğru şekilde tahmin etme potansiyelini ortaya koymuştur.

Katılımcılar-arası sınıflandırmada iş yükünün tahmin edilmesi için içerdiği bilgiye göre en etkili bulunan özniteliklerin frontal bölgedeki teta bant güçleri olduğu belirlenmiştir. En önemli özniteliklere ilişkin gözlemlenen bu sonuç, mevcut literatürdeki bulgularla

tutarlı bir şekilde uyumludur (Di Flumeri vd., 2018; Islam vd., 2020). Frontal bölgedeki teta bant gücünün görev karmaşıklığı, zihinsel iş yükü, durumsal farkındalık vb. faktörler açısından etkin bir gösterge olduğu bilinmektedir. Bununla birlikte katılımcı-bazında yapılan sınıflandırmada her katılımcı için farklı özniteliklerin ön plana çıktığı görülmüştür. Frontal bölgedeki teta bant güçlerinin yanında, beta ve gama bant güçleri de bazı katılımcıların iş yükünün tahmin edilmesinde en etkili öznitelikler olmuştur. Bu durum zihinsel iş yükünün kişiye özel olarak ele alınması ve incelenmesinin önemini vurgulamaktadır. Sürücülerin yaş ve cinsiyet gibi bireysel özelliklerinin ise genellikle en önemli ve en ayırt edici öznitelikler arasında bulunmadığı tespit edilmiştir.

Bu tez çalışması tamamen gerçek trafikte kaydedilen EEG sinyallerini kullanarak, farklı sürüş koşullarının sürücülerin mental iş yükü ile ilişkisini göstermesi ve çalışmaya özgü etiketleme yaklaşımı ile etiketlenen (trafik yoğunluğu ve yol tipine göre) EEG verisini makine öğrenmesi yöntemleri ile sınıflandırması açısından literatüre katkı sağlamaktadır. Bu tez çalışmasında elde edilen bulgular sürüş koşulları ve sürücülerin zihinsel iş yükü arasındaki ilişkinin daha iyi anlaşılmasına olanak sağlamıştır. Aynı zamanda yol güvenliğini sağlamak ve genel sürüş performansını geliştirmek için sürücülerin zihinsel durumlarını izlemeyi ve yönetmeyi amaçlayan akıllı sistemlerin geliştirilmesi konusunda pratik bilgiler sağlamaktadır. Burada sunulan sonuçlar otonom sürüş, ulaşım ve insan-makine etkileşimi alanında gelecekteki araştırma ve uygulamalara zemin hazırlayabilecektir. Ayrıca gelecek çalışmalarda gerçek trafikteki EEG verisinin derin öğrenme modelleri ile sınıflandırılması, iş yükünü temsil eden sınıf sayısının arttırılarak daha hassas bir tahminin sağlanması düşünülebilir. Tüm bu çalışmaların gerçek zamanlı olarak yapılabilmesi de gelecekteki uygulamalar açısından faydalı olacaktır.

KAYNAKLAR

Abd Rahman, N. I., Md Dawal, S. Z., & Yusoff, N. (2020). Driving mental workload and performance of ageing drivers. *Transportation Research Part F: Traffic Psychology and Behaviour*, *69*, 265-285. https://doi.org/10.1016/j.trf.2020.01.019

Abhang, P. A., Gawali, B. W., & Mehrotra, S. C. (2016). *Introduction to EEG- and Speech-Based Emotion Recognition*. Academic Press.

Ahn, S., Nguyen, T., Jang, H., Kim, J. G., & Jun, S. C. (2016). Exploring neuro-physiological correlates of drivers' mental fatigue caused by sleep deprivation using simultaneous EEG, ECG, and fNIRS data. *Frontiers in Human Neuroscience*, *10*(MAY2016). https://doi.org/10.3389/fnhum.2016.00219

Akgüngör, A. P., & Doan, E. (2009). An application of modified Smeed, adapted Andreassen and artificial neural network accident models to three metropolitan cities of Turkey. *Scientific Research and Essay*, *4*(9), 906-913. http://www.academicjournals.org/SRE

Almogbel, M. A., Dang, A. H., & Kameyama, W. (2018). EEG-signals based cognitive workload detection of vehicle driver using deep learning. *International Conference on Advanced Communication Technology, ICACT*, *2018-February*, 256-259. https://doi.org/10.23919/ICACT.2018.8323716

Antonenko, P., Paas, F., Grabner, R., & van Gog, T. (2010). Using Electroencephalography to Measure Cognitive Load. Içinde *Educational Psychology Review* (C. 22, Sayı 4, ss. 425-438). https://doi.org/10.1007/s10648-010-9130-y

Aricò, P., Borghini, G., Di Flumeri, G., Colosimo, A., Bonelli, S., Golfetti, A., Pozzi, S., Imbert, J. P., Granger, G., Benhacene, R., & Babiloni, F. (2016). Adaptive automation triggered by EEG-based mental workload index: A passive brain-computer interface application in realistic air traffic control environment. *Frontiers in Human Neuroscience*, *10*(OCT2016). https://doi.org/10.3389/fnhum.2016.00539

Aygun, A., Lyu, B., Nguyen, T., Haga, Z., Aeron, S., & Scheutz, M. (2022). Cognitive Workload Assessment via Eye Gaze and EEG in an Interactive Multi-Modal Driving Task. *ACM International Conference Proceeding Series*, 337-348. https://doi.org/10.1145/3536221.3556610

Babalık, F. C. (2016). *Mühendisler için Ergonomi - İşbilim* (5. Baskı). Dora.

Bajwa, G., Fazeen, M., & Dantu, R. (2019). *Detecting driver distraction using stimuli-response EEG analysis*. https://doi.org/https://doi.org/10.48550/arXiv.1904.09100

Bakshi, V. (2018). *Towards Practical Driver Cognitive Workload Monitoring via Electroencephalography* [Master of Applied Science Thesis]. University of Toronto.

Baldwin, C. L., & Penaranda, B. N. (2012). Adaptive training using an artificial neural network and EEG metrics for within- and cross-task workload classification. *NeuroImage*, *59*(1), 48-56. https://doi.org/10.1016/j.neuroimage.2011.07.047

Barua, S., Ahmed, M. U., & Begum, S. (2017). Classifying drivers' cognitive load using EEG signals. *Studies in Health Technology and Informatics*, *237*. https://doi.org/10.3233/978-1-61499-761-0-99

Barua, S., Ahmed, M. U., & Begum, S. (2020). Towards Intelligent Data Analytics: A Case Study in Driver Cognitive Load Classification. *Brain Sciences*, *10*(8), 526. https://doi.org/10.3390/brainsci10080526

Becerra-Sánchez, P., Reyes, A., & Guerrero-Ibañez, A. (2020). Feature selection model based on eeg signals for assessing the cognitive workload in drivers. *Sensors*, *20*(20), 1-25. https://doi.org/10.3390/s20205881

Berka, C., Levendowski, D. J., Lumicao, M. N., Yau, A., Davis, G., Zivkovic, V. T., Olmstead, R. E., Tremoulet, P. D., & Craven, P. L. (2007). EEG Correlates of Task Engagement and Mental Workload in Vigilance, Learning, and Memory Tasks. *Aviation, Space, and Environmental Medicine*, *78*(5), B231-B244.

Borghini, G., Astolfi, L., Vecchiato, G., Mattia, D., & Babiloni, F. (2014). Measuring neurophysiological signals in aircraft pilots and car drivers for the assessment of mental workload, fatigue and drowsiness. Içinde *Neuroscience and Biobehavioral Reviews* (C. 44, ss. 58-75). Elsevier Ltd. https://doi.org/10.1016/j.neubiorev.2012.10.003

Borghini, G., Vecchiato, G., Toppi, J., Astolfi, L., Maglione, A., Isabella, R., Caltagirone, C., Kong, W., Wei, D., Zhou, Z., Polidori, L., Vitiello, S., & Babiloni, F. (2012). Assessment of mental fatigue during car driving by using high resolution EEG activity and neurophysiologic indices. *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 6442-6445. https://doi.org/10.1109/EMBC.2012.6347469

Byers, J. C., Bittner Jr, A. C., & Hill, S. G. (1989). Traditional and raw task load index (TLX) correlations: Are paired comparisons necessary? Içinde A. Mital (Ed.), *Advances in Industrial Ergonomics and Safety I* (ss. 481-485). Taylor and Francis.

Causse, M., Fabre, E., Giraudet, L., Gonzalez, M., & Peysakhovich, V. (2015). EEG/ERP as a Measure of Mental Workload in a Simple Piloting Task. *Procedia Manufacturing*, *3*, 5230-5236. https://doi.org/10.1016/j.promfg.2015.07.594

Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research*, *16*, 321-357. https://doi.org/10.1613/jair.953

Çelik, M. (2009). *Veri Madenciliğinde Kullanılan Sınıflandırma Yöntemleri ve Bir Uygulama* [Yüksek Lisans Tezi]. İstanbul Üniversitesi Sosyal Bilimler Enstitüsü.

Das, D., Chatterjee, D., & Sinha, A. (2013). Unsupervised approach for measurement of cognitive load using EEG signals. *13th IEEE International Conference on BioInformatics and BioEngineering*, 1-6. https://doi.org/10.1109/BIBE.2013.6701686

Dehais, F., & Ayaz, H. (2018). Progress and direction in neuroergonomics. Içinde *Neuroergonomics: The Brain at Work and in Everyday Life* (ss. 3-7). Elsevier. https://doi.org/10.1016/B978-0-12-811926-6.00001-4

Di Flumeri, G., Borghini, G., Aricò, P., Sciaraffa, N., Lanzi, P., Pozzi, S., Vignali, V., Lantieri, C., Bichicchi, A., Simone, A., & Babiloni, F. (2018). EEG-based mental workload neurometric to evaluate the impact of different traffic and road conditions in real driving settings. *Frontiers in Human Neuroscience*, *12*. https://doi.org/10.3389/fnhum.2018.00509

Diwakar, A., Kaur, T., Ralekar, C., & Gandhi, T. K. (2020, Aralık 10). Deep Learning Identifies Brain Cognitive Load Via EEG Signals. *2020 IEEE 17th India Council International Conference, INDICON 2020*. https://doi.org/10.1109/INDICON49873.2020.9342222

Drouin-Picaro, A., Albuquerque, I., Gagnon, J.-F., Lafond, D., & Falk, T. H. (2017). *EEG Coupling Features: Towards Mental Workload Measurement Based on Wearables*. https://doi.org/10.0/Linux-x86_64

Dünya Sağlık Örgütü. (2018). *Global Status Report on Road Safety*.

Fu, S., & Parasuraman, R. (2007). Event-Related Potentials (ERPs) in Neuroergonomics. Içinde R. Parasuraman & M. Rizzo (Ed.), *Neuroergonomics: The Brain at Work* (ss. 32-50). Oxford University Press.

Gabaude, C., Baracat, B., Jallais, C., Bonniaud, M., & Fort, A. (2012). Cognitive load measurement while driving. Içinde D. de Waard, K. Brookhuis, F. Dehais, C. Weikert, S. Röttger, D. Manzey, S. Biede, F. Reuzeau, & P. Terrier (Ed.), *Proceedings HFES Europe Chapter Conference* (ss. 67-80). Human Factors: a view from an integrative perspective.

Galy, E., Cariou, M., & Mélan, C. (2012). What is the relationship between mental workload factors and cognitive load types? *International Journal of Psychophysiology*, *83*(3), 269-275. https://doi.org/10.1016/j.ijpsycho.2011.09.023

García-Monge, A., Rodríguez-Navarro, H., González-Calvo, G., & Bores-García, D. (2020). Brain Activity during Different Throwing Games: EEG Exploratory Study. *International Journal of Environmental Research and Public Health*, *17*(18), 6796-6814. https://doi.org/10.3390/ijerph17186796

Gevins, A., & Smith, M. E. (2003). Neurophysiological measures of cognitive workload during human–computer interaction. *Theoretical Issues in Ergonomics Science*, *4*(1-2), 113-131. https://doi.org/10.1080/14639220210159717

Guo, L., Pang, L., Wanyan, X., Qu, H., & Zhang, J. (2021). Classification of mental workload from beta of EEG data using stochastic configuration network (SCN). *CSAA/IET International Conference on Aircraft Utility Systems (AUS 2020)*, 595-598. https://doi.org/10.1049/icp.2021.0148

Gupta, A., Siddhad, G., Pandey, V., Roy, P. P., & Kim, B. G. (2021). Subject-specific cognitive workload classification using eeg-based functional connectivity and deep learning. *Sensors*, *21*(20). https://doi.org/10.3390/s21206710

Harputlu Aksu, Ş., & Çakıt, E. (2022). Classifying mental workload using EEG data: A machine learning approach. *Neuroergonomics and Cognitive Engineering*, *42*. https://doi.org/10.54941/ahfe1001820

Hart, S. G., & Staveland, L. E. (1988). Development of NASA-TLX (Task Load Index): Results of Empirical and Theoretical Research. *Advances in Psychology*, *52*, 139-183. https://doi.org/10.1016/S0166-4115(08)62386-9

Holm, A., Lukander, K., Korpela, J., Sallinen, M., & Müller, K. M. I. (2009). Estimating brain load from the EEG. *The Scientific World Journal*, *9*, 639-651. https://doi.org/10.1100/tsw.2009.83

Homan, R. W., Herman, J., & Purdy, P. (1987). Cerebral Location of International 10–20 System Electrode Placement. *Electroencephalography and Clinical Neurophysiology*, *66*(4), 376-382. https://doi.org/10.1016/0013-4694(87)90206-9

Huang, J., Liu, Y., & Peng, X. (2022). Recognition of driver's mental workload based on physiological signals, a comparative study. *Biomedical Signal Processing and Control*, *71*, 103094. https://doi.org/10.1016/j.bspc.2021.103094

Islam, M. R., Barua, S., Ahmed, M. U., Begum, S., Aricò, P., Borghini, G., & Flumeri, G. Di. (2020). A novel mutual information based feature set for drivers' mental workload evaluation using machine learning. *Brain Sciences*, *10*(8), 1-23. https://doi.org/10.3390/brainsci10080551

Islam, M. R., Barua, S., Ahmed, M. U., Begum, S., & Di Flumeri, G. (2019). Deep Learning for Automatic EEG Feature Extraction: An Application in Drivers' Mental Workload Classification. Içinde L. Longo & M. Leva (Ed.), *Human Mental*

Workload Models and Applications (ss. 121-135). Springer. https://doi.org/10.1007/978-3-030-32423-0_8

James, D. R. C. (2012). *Neuroergonomic Assessment of the Robotic Enhancement of Surgery*.

Jap, B. T., Lal, S., Fischer, P., & Bekiaris, E. (2009). Using EEG spectral components to assess algorithms for detecting fatigue. *Expert Systems with Applications*, *36*(2 PART 1), 2352-2359. https://doi.org/10.1016/j.eswa.2007.12.043

Kim, H. S., Yoon, D., Shin, H. S., & Park, C. H. (2019). Predicting the EEG Level of a Driver Based on Driving Information. *IEEE Transactions on Intelligent Transportation Systems*, *20*(4), 1215-1225. https://doi.org/10.1109/TITS.2018.2848300

Klimesch, W. (1999). EEG alpha and theta oscillations reflect cognitive and memory performance: a review and analysis. *Brain Research Reviews*, *29*, 169-195.

Kotsiantis, S. B. (2007). Supervised Machine Learning: A Review of Classification Techniques. Içinde *Informatica* (C. 31).

Kramer, O. (2013). K-Nearest Neighbors. Içinde *Dimensionality Reduction with Unsupervised Nearest Neighbors* (C. 51, ss. 13-23). Springer. https://doi.org/10.1007/978-3-642-38652-7_2

Kumar, N., & Kumar, J. (2016). Measurement of Cognitive Load in HCI Systems Using EEG Power Spectrum: An Experimental Study. *Procedia Computer Science*, *84*, 70-78. https://doi.org/10.1016/j.procs.2016.04.068

Kutafina, E., Heiligers, A., Popovic, R., Brenner, A., Hankammer, B., Jonas, S. M., Mathiak, K., & Zweerings, J. (2021). Tracking of mental workload with a mobile eeg sensor. *Sensors*, *21*(15). https://doi.org/10.3390/s21155205

Lees, M. N., Cosman, J. D., Lee, J. D., Fricke, N., & Rizzo, M. (2010). Translating cognitive neuroscience to the driver's operational environment: A neuroergonomic approach. Içinde *American Journal of Psychology Winter* (C. 123, Sayı 4).

Lew, R. (2013). *Assessing Cognitive Workload From Multiple Physiological Measures Using Wavelets and Machine Learning*. College of Graduate Studies University of Idaho.

Liang, Y., Liang, W., Qu, J., & Yang, J. (2018). Experimental Study on EEG with Different Cognitive Load. *Proceedings - 2018 IEEE International Conference on Systems, Man, and Cybernetics, SMC 2018*, 4351-4356. https://doi.org/10.1109/SMC.2018.00735

Liu, Y., Ayaz, H., & Shewokis, P. A. (2017). Multisubject "learning" for mental workload classification using concurrent EEG, fNIRS, and physiological measures. *Frontiers in Human Neuroscience*, *11*. https://doi.org/10.3389/fnhum.2017.00389

Lohani, M., Payne, B. R., & Strayer, D. L. (2019). A review of psychophysiological measures to assess cognitive states in real-world driving. Içinde *Frontiers in Human Neuroscience* (C. 13). Frontiers Media S.A. https://doi.org/10.3389/fnhum.2019.00057

Lundqvist, M., Herman, P., Warden, M. R., Brincat, S. L., & Miller, E. K. (2018). Gamma and beta bursts during working memory readout suggest roles in its volitional control. *Nature Communications*, *9*(1), 394. https://doi.org/10.1038/s41467-017-02791-8

McDonnell, A. S., Simmons, T. G., Erickson, G. G., Lohani, M., Cooper, J. M., & Strayer, D. L. (2023). This Is Your Brain on Autopilot: Neural Indices of Driver Workload and Engagement During Partial Vehicle Automation. *Human Factors:*

The Journal of the Human Factors and Ergonomics Society, *65*(7), 1435-1450. https://doi.org/10.1177/00187208211039091

Miyake, S. (2001). Multivariate workload evaluation combining physiological and subjective measures. *International Journal of Psychophysiology*, *40*(3), 233-238. https://doi.org/10.1016/S0167-8760(00)00191-4

Morales, J. M., Díaz-Piedra, C., Rieiro, H., Roca-González, J., Romero, S., Catena, A., Fuentes, L. J., & Di Stasi, L. L. (2017). Monitoring driver fatigue using a single-channel electroencephalographic device: A validation study by gaze-based, driving performance, and subjective data. *Accident Analysis and Prevention*, *109*, 62-69. https://doi.org/10.1016/j.aap.2017.09.025

Muller-Putz, G. R., Scherer, R., Neuper, C., & Pfurtscheller, G. (2006). Steady-state somatosensory evoked potentials: suitable brain signals for brain-computer interfaces? *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, *14*(1), 30-37. https://doi.org/10.1109/TNSRE.2005.863842

Navarro, J., Reynaud, E., & Osiurak, F. (2018). Neuroergonomics of car driving: A critical meta-analysis of neuroimaging data on the human brain behind the wheel. Içinde *Neuroscience and Biobehavioral Reviews* (C. 95, ss. 464-479). Elsevier Ltd. https://doi.org/10.1016/j.neubiorev.2018.10.016

NHTSA. (2023). *Distracted Driving in 2021*.

Niedermeyer, E., & da Silva, F. L. (2005). *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields* (5. bs). Lippincott Williams & Wilkins.

Niso, G., Romero, E., Moreau, J. T., Araujo, A., & Krol, L. R. (2023). Wireless EEG: A survey of systems and studies. *NeuroImage*, *269*. https://doi.org/10.1016/j.neuroimage.2022.119774

Noh, Y., Kim, S., Jang, Y. J., & Yoon, Y. (2021). Modeling Individual Differences in Driver Workload Inference Using Physiological Data. *International Journal of Automotive Technology*, *22*(1), 201-212. https://doi.org/10.1007/s12239-021-0020-8

O'Donnel, R. D., & Eggemeier, F. T. (1986). Workload Assessment Methodology. Içinde K. Boff, L. Kaufman, & J. Thomas (Ed.), *Handbook of Perception and Human Performance* (1. bs, s. 42). Wiley.

Ozkan, N. F., & Kahya, E. (2014). Measurement of Cognitive Workload by Use of Combined Methods Including Brain-Computer Interfaces. Içinde P. Vink (Ed.), *Advances in Social and Organizational Factors* (C. 9, ss. 458-468). AHFE International.

Paas, F. (1992). Training strategies for attaining transfer of problem-solving skill in statistics: A cognitive-load approach. *Journal of Educational Psychology*, *84*(4), 429-434. https://doi.org/10.1037/0022-0663.84.4.429

Paas, F., Renkl, A., & Sweller, J. (2003). Cognitive Load Theory and Instructional Design: Recent Developments. *Educational Psychologist*, *38*(1), 1-4. https://doi.org/10.1207/S15326985EP3801_1

Paas, F., Tuovinen, J., Tabbers, H., & Van Gerven, P. (2003). Cognitive Load Measurement as a Means to Advance Cognitive Load Theory. *Educational Psychologist*, *38*(1), 63-71. https://doi.org/10.1207/S15326985EP3801_8

Parasuraman, R. (2003). Neuroergonomics: Research and practice. *Theoretical Issues in Ergonomics Science*, *4*(1-2), 5-20. https://doi.org/10.1080/14639220210199753

Parasuraman, R., & Rizzo, M. (2007). Introduction to Neuroergonomics. Içinde R. Parasuraman & M. Rizzo (Ed.), *Neuroergonomics: The Brain at Work* (ss. 3-12). Oxford University Press.

Parasuraman, R., Sheridan, T. B., & Wickens, C. D. (2008). Situation Awareness, Mental Workload, and Trust in Automation: Viable, Empirically Supported Cognitive Engineering Constructs. *Journal of Cognitive Engineering and Decision Making*, *2*(2), 140-160. https://doi.org/10.1518/155534308X284417

Perpetuini, D., Filippini, C., Nocco, S., Tritto, M., Cardone, D., & Merla, A. (2022). A Machine Learning Approach to Classify Driver Mental Workload as Assessed by Electroencephalography through Infrared Thermal Imaging. *2022 10th E-Health and Bioengineering Conference, EHB 2022*. https://doi.org/10.1109/EHB55594.2022.9991380

Pfurtscheller, G., & da Silva, F. H. L. (1999). Event-related EEG/MEG synchronization and desynchronization: basic principles. *Clinical Neurophysiology*, *110*(11), 1842-1857. https://doi.org/10.1016/S1388-2457(99)00141-8

Posner, M. I. (2012). Expanding horizons in ergonomics research. Içinde *NeuroImage* (C. 59, Sayı 1, ss. 149-153). https://doi.org/10.1016/j.neuroimage.2011.07.060

Rahman, H., Ahmed, M. U., Barua, S., & Begum, S. (2020). Non-contact-based driver's cognitive load classification using physiological and vehicular parameters. *Biomedical Signal Processing and Control*, *55*. https://doi.org/10.1016/j.bspc.2019.101634

Reid, G. B., & Nygren, T. E. (1988). The Subjective Workload Assessment Technique: A Scaling Procedure for Measuring Mental Workload. *Advances in Psychology*, *52*, 185-218. https://doi.org/10.1016/S0166-4115(08)62387-0

Rigatti, S. J. (2017). Random Forest. *Journal of Insurance Medicine*, *47*(1), 31-39. https://doi.org/10.17849/insm-47-01-31-39.1

Riono, Suparno, & Adi Bandono. (2018). Analysis of Mental Workload With Integrating NASA TLX and Fuzyy Method. *International Journal of ASRO*, *9*(1), 37-45. https://doi.org/10.37875/asro.v9i1.57

Rupp, G., Berka, C., Meghdadi, A. H., Karić, M. S., Casillas, M., Smith, S., Rosenthal, T., McShea, K., Sones, E., & Marcotte, T. D. (2019). EEG-Based Neurocognitive Metrics May Predict Simulated and On-Road Driving Performance in Older Drivers. *Frontiers in Human Neuroscience*, *12*. https://doi.org/10.3389/fnhum.2018.00532

Saha, A., Minz, V., Bonela, S., Sreeja, S. R., Chowdhury, R., & Samanta, D. (2018). Classification of EEG signals for cognitive load estimation using deep learning architectures. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, *11278 LNCS*, 59-68. https://doi.org/10.1007/978-3-030-04021-5_6

Sibi, S., Ayaz, H., Kuhns, D. P., Sirkin, D. M., & Ju, W. (2016). Monitoring driver cognitive load using functional near infrared spectroscopy in partially autonomous cars. *2016 IEEE Intelligent Vehicles Symposium (IV)*, 419-425. https://doi.org/10.1109/IVS.2016.7535420

Siuly, S., Li, Y., & Zhang, Y. (2016). *EEG Signal Analysis and Classification Techniques and Applications*. Springer International Publishing.

Solís-Marcos, I., & Kircher, K. (2019). Event-related potentials as indices of mental workload while using an in-vehicle information system. *Cognition, Technology and Work*, *21*(1), 55-67. https://doi.org/10.1007/s10111-018-0485-z

Strayer, D. L., Turrill, J., Cooper, J. M., Coleman, J. R., Medeiros-Ward, N., & Biondi, F. (2015). Assessing Cognitive Distraction in the Automobile. *Human Factors*, *57*(8), 1300-1324. https://doi.org/10.1177/0018720815575149

Sweller, J. (1988). Cognitive Load During Problem Solving: Effects on Learning. *Cognitive Science*, *12*(2), 257-285. https://doi.org/10.1016/0364-0213(88)90023-7

Sweller, J. (1994). Cognitive load theory, learning difficulty, and instructional design. *Learning and Instruction*, *4*(4), 295-312. https://doi.org/10.1016/0959-4752(94)90003-5

Sweller, J. (2011). *Cognitive Load Theory* (ss. 37-76). https://doi.org/10.1016/B978-0-12-387691-1.00002-8

Türkiye İstatistik Kurumu. (2023a, Mayıs). *Karayolu Trafik Kaza İstatistikleri*. https://data.tuik.gov.tr/Bulten/Index?p=Karayolu-Trafik-Kaza-Istatistikleri-2022-49513

Türkiye İstatistik Kurumu. (2023b, Mayıs). *Motorlu Kara Taşıtları*. https://data.tuik.gov.tr/Bulten/Index?p=Motorlu-Kara-Tasitlari-Mayis-2023-49426#:~:text=May%C4%B1s%20ay%C4%B1nda%201%20milyon%20104,sini%20%C3%B6zel%20ama%C3%A7l%C4%B1%20ta%C5%9F%C4%B1tlar%20olu%C5%9Fturdu.

Venkatraman, V., Richard, C. M., Magee, K., & Johnson, K. (2021). *Countermeasures that work: A highway safety countermeasures guide for State Highway Safety Offices*.

Wang, Q., & Mu, Z. (2021). Application of music in relief of driving fatigue based on EEG signals. *Eurasip Journal on Advances in Signal Processing*, *2021*(1). https://doi.org/10.1186/s13634-021-00794-8

Wang, Y. K., Jung, T. P., & Lin, C. T. (2018). Theta and alpha oscillations in attentional interaction during distracted driving. *Frontiers in Behavioral Neuroscience*, *12*. https://doi.org/10.3389/fnbeh.2018.00003

World Health Organization. (2023, Aralık). *Road traffic injuries*. https://www.who.int/news-room/fact-sheets/detail/road-traffic-injuries

Xie, B., & Salvendy, G. (2000). Prediction of Mental Workload in Single and Multiple Tasks Environments. *International Journal of Cognitive Ergonomics*, *4*(3), 213-242. https://doi.org/10.1207/S15327566IJCE0403_3

Yamada, F. (1998). Frontal midline theta rhythm and eyeblinking activity during a VDT task and a video game: Useful tools for psychophysiology in ergonomics. *Ergonomics*, *41*(5), 678-688. https://doi.org/10.1080/001401398186847

Yang, H., Wu, J., Hu, Z., & Lv, C. (2023). Real-Time Driver Cognitive Workload Recognition: Attention-Enabled Learning with Multimodal Information Fusion. *IEEE Transactions on Industrial Electronics*. https://doi.org/10.1109/TIE.2023.3288182

Yin, Z., Zhao, M., Zhang, W., Wang, Y., Wang, Y., & Zhang, J. (2019). Physiological-signal-based mental workload estimation via transfer dynamical autoencoders in a deep learning framework. *Neurocomputing*, *347*, 212-229. https://doi.org/10.1016/j.neucom.2019.02.061

Zammouri, A., Chraa-Mesbahi, S., Ait Moussa, A., Zerouali, S., Sahnoun, M., Tairi, H., & Mahraz, A. M. (2017). Brain waves-based index for workload estimation and mental effort engagement recognition. *Journal of Physics: Conference Series*, *904*(1). https://doi.org/10.1088/1742-6596/904/1/012008

Zhang, X. (2021). *Driver Mental States Detection during Highly Automated Driving by Decoding Brain Signals* [PhD.]. Berlin Technical University.

Zhao, C., Zhao, M., Liu, J., & Zheng, C. (2012). Electroencephalogram and electrocardiograph assessment of mental fatigue in a driving simulator. *Accident Analysis and Prevention, 45*, 83-90. https://doi.org/10.1016/j.aap.2011.11.019

EKLER

EK 1 NASA-RTLX Uygulama Sayfası

EK 2 Katılımcı Bilgi ve Onay Formu

EK 3 Katılımcı-Bazında Veri Kümeleri 1 için Optimal Parametreler

EK 4 Katılımcı-Bazında Veri Kümeleri 2 için Optimal Parametreler

EK 5 Katılımcı-Bazında Veri Kümeleri 1 için Model Performansları

EK 6 Katılımcı-Bazında Veri Kümeleri 2 için Model Performansları

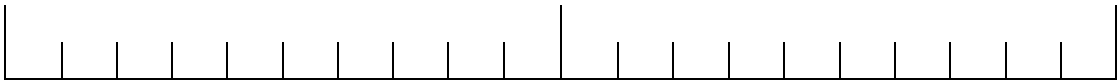
EK 1 NASA-RTLX Uygulama Sayfası

Ad-Soyad:

NASA HAM GÖREV YÜKÜ İNDEKSİ (NASA-RTLX)

Yaptığınız görev için aşağıdaki soruları 0-100 arasında puanlayınız.

Zihinsel Zorluk: Görev zihinsel olarak ne kadar zorlayıcıydı?



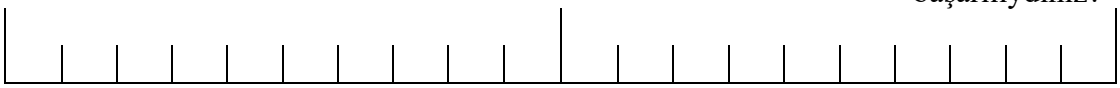
Fiziksel Zorluk: Görev fiziksel olarak ne kadar zorlayıcıydı?



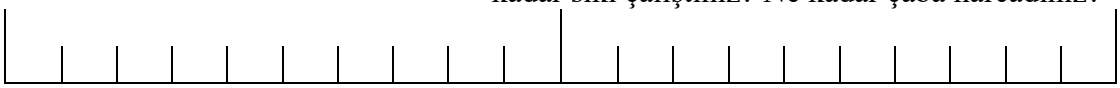
Geçici Zorluk: Görevin hızı ne kadar aceleye veya telaşa sebep oluyordu?



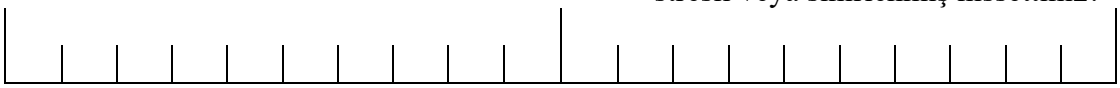
Performans: Yapmanız istenen işi tamamlamada ne kadar başarılıydınız?



Çaba: Belirttiğiniz performans düzeyini gerçekleştirmek için ne kadar sıkı çalıştınız? Ne kadar çaba harcadınız?



Kaygı / Boşa Çaba: Görev esnasında ne kadar güvensiz, yılgın, tedirgin, stresli veya sinirlenmiş hissettiniz?



Çok Düşük Orta Çok Yüksek

EK 2 Katılımcı Bilgi ve Onay Formu

KATILIMCI BİLGİ VE ONAY FORMU

Deneylerde elde edilen veriler yalnızca "Otomobil Sürücülerinin Farklı Trafik ve Yol Koşullarındaki Bilişsel Yüklerinin Araştırılması" isimli doktora tezi ve ilgili yayınlar için kullanılacaktır. Kişisel bilgileriniz herhangi bir kişi veya kurumla paylaşılmayacaktır.

İsim	
Yaş	
Cinsiyet	
Eğitim	
Otomobil sürme tecrübesi (yıl)	
Yıllık ortalama otomobil sürme mesafesi (km)	
Gözlük veya lens kullanım durumu	

Gönüllü olarak katıldığım deneylerde elde edilen verilerin tez ve yayınlarda kullanılmasını onaylıyorum.

Tarih

İmza

Katılımcı İletişim Bilgileri:

EK 3 Katılımcı-Bazında Veri Kümeleri 1 için Optimal Parametreler

	RO			SVM		kNN			YSA		
	Ağaç sayısı	**Kriter**	**Maksimum seviye**	**Kernel katsayısı (gama)**	**Kernel fonksiyonu**	**Algoritma**	**Komşu sayısı**	**Ağırlık fonksiyonu**	**Çözücü**	**Aktivasyon fonksiyonu**	**Gizli katman sayısı ve boyutları**
Deney 2	500	Entropi	Sınırsız	1/N	Lineer	Otomatik	35	Mesafeye bağlı	Quasi-Newton	ReLU	(10,)
Deney 3	500	Gini impuritesi	Sınırsız	1/N	Polinomiyal	Otomatik	3	Mesafeye bağlı	Quasi-Newton	Hiperbolik tanjant	(100,100,)
Deney 4	500	Entropi	Sınırsız	1/N	Radyal temelli	Otomatik	3	Mesafeye bağlı	Adam	ReLU	(100,)
Deney 5	500	Entropi	Sınırsız	1/N	Polinomiyal	Otomatik	3	Mesafeye bağlı	Adam	ReLU	(100,100,)
Deney 6	100	Gini impuritesi	Sınırsız	1/N	Radyal temelli	Otomatik	33	Mesafeye bağlı	Adam	ReLU	(100,)
Deney 7	200	Gini impuritesi	Sınırsız	1/N	Radyal temelli	Otomatik	33	Düzgün	Adam	ReLU	(10,)
Deney 8	200	Entropi	Sınırsız	1/N	Lineer	Otomatik	5	Düzgün	Adam	ReLU	(100,)
Deney 9	300	Entropi	Sınırsız	1/N	Polinomiyal	Otomatik	5	Mesafeye bağlı	Adam	ReLU	(100,100,)
Deney 10	200	Entropi	Sınırsız	1/N	Radyal temelli	Otomatik	7	Mesafeye bağlı	Adam	ReLU	(100,100,)
Deney 11	500	Gini impuritesi	Sınırsız	1/N	Polinomiyal	Otomatik	7	Düzgün	Adam	ReLU	(100,)
Deney 12	100	Gini impuritesi	Sınırsız	1/N	Polinomiyal	Otomatik	3	Mesafeye bağlı	Adam	ReLU	(100,)
Deney 13	300	Entropi	Sınırsız	1/N	Radyal temelli	Otomatik	7	Mesafeye bağlı	Adam	ReLU	(100,)
Deney 14	100	Entropi	Sınırsız	1/N	Radyal temelli	Otomatik	9	Mesafeye bağlı	Adam	ReLU	(100,)

Deney 15	500	Gini impuritesi	Sınırsız	1/N	Polinomiyal	Otomatik	3	Mesafeye bağlı	Adam	Hiperbolik tanjant	(100,100,)
Deney 16	500	Gini impuritesi	Sınırsız	1/N	Lineer	Otomatik	5	Düzgün	Adam	ReLU	(100,)
Deney 17	300	Entropi	Sınırsız	1/N	Radyal temelli	Otomatik	3	Mesafeye bağlı	Adam	ReLU	(10,)
Deney 18	300	Gini impuritesi	Sınırsız	1/N	Polinomiyal	Otomatik	31	Mesafeye bağlı	Adam	ReLU	(100,)
Deney 20	200	Entropi	Sınırsız	1/N	Radyal temelli	Otomatik	3	Mesafeye bağlı	Adam	ReLU	(100,)
Deney 21	100	Gini impuritesi	Sınırsız	1/N	Polinomiyal	Otomatik	33	Mesafeye bağlı	Adam	ReLU	(100,100,)
Deney 22	100	Entropi	Sınırsız	1/N	Radyal temelli	Otomatik	7	Düzgün	Adam	ReLU	(10,10,)
Deney 23	300	Gini impuritesi	Sınırsız	1/N	Radyal temelli	Otomatik	5	Düzgün	Adam	Hiperbolik tanjant	(100,100,)
Deney 24	100	Entropi	Sınırsız	1/N	Lineer	Otomatik	7	Mesafeye bağlı	Adam	Aktivasyon yok	(100,100,)
Deney 25	500	Gini impuritesi	Sınırsız	1/N	Radyal temelli	Otomatik	5	Düzgün	Adam	ReLU	(100,100,)
Deney 26	200	Gini impuritesi	Sınırsız	1/N	Polinomiyal	Otomatik	21	Düzgün	Adam	ReLU	(100,100,)
Deney 28	100	Entropi	Sınırsız	1/N	Radyal temelli	Otomatik	5	Mesafeye bağlı	Adam	ReLU	(100,)
Deney 29	300	Entropi	Sınırsız	1/N	Lineer	Otomatik	7	Mesafeye bağlı	Adam	ReLU	(100,)
Deney 30	500	Entropi	Sınırsız	1/N	Lineer	Otomatik	5	Mesafeye bağlı	Adam	ReLU	(100,)
Deney 31	500	Entropi	Sınırsız	1/N	Polinomiyal	Otomatik	5	Düzgün	Adam	ReLU	(100,)
Deney 32	500	Entropi	Sınırsız	1/N	Polinomiyal	Otomatik	9	Mesafeye bağlı	Adam	ReLU	(100,)
Deney 33	500	Entropi	Sınırsız	1/N	Polinomiyal	Otomatik	5	Düzgün	Quasi-Newton	ReLU	(100,100,)
Deney 34	100	Gini impuritesi	Sınırsız	1/N	Radyal temelli	Otomatik	5	Düzgün	Adam	ReLU	(100,)

Deney 35	100	Gini impuritesi	Sınırsız	1/N	Radyal temelli	Otomatik	5	Düzgün	Adam	ReLU	(100,)
Deney 36	100	Gini impuritesi	Sınırsız	1/N	Polinomiyal	Otomatik	5	Mesafeye bağlı	Adam	ReLU	(100,)
Deney 37	300	Gini impuritesi	Sınırsız	1/N	Radyal temelli	Otomatik	5	Düzgün	Adam	ReLU	(100,)
Deney 38	100	Entropi	Sınırsız	1/N	Radyal temelli	Otomatik	9	Düzgün	Adam	ReLU	(100,)
Deney 39	300	Entropi	Sınırsız	1/N	Radyal temelli	Otomatik	9	Mesafeye bağlı	Adam	ReLU	(100,100,)

EK 4 Katılımcı-Bazında Veri Kümeleri 2 için Optimal Parametreler

	RO			SVM		kNN			YSA		
	Ağaç sayısı	**Kriter**	**Maksimum seviye**	**Kernel katsayısı (gama)**	**Kernel fonksiyonu**	**Algoritma**	**Komşu sayısı**	**Ağırlık fonksiyonu**	**Çözücü**	**Aktivasyon fonksiyonu**	**Gizli katman sayısı ve boyutları**
Deney 2	300	Gini impuritesi	Sınırsız	$1/N$	Lineer	Otomatik	9	Mesafeye bağlı	Adam	Aktivasyon yok	(10,)
Deney 3	500	Entropi	Sınırsız	$1/N$	Lineer	Otomatik	29	Mesafeye bağlı	Adam	ReLU	(100,)
Deney 4	300	Entropi	Sınırsız	$1/N$	Polinomiyal	Otomatik	5	Düzgün	Adam	ReLU	(100,100)
Deney 5	300	Gini impuritesi	Sınırsız	$1/N$	Lineer	Otomatik	5	Düzgün	Adam	Hiperbolik tanjant	(10,10)
Deney 6	500	Entropi	Sınırsız	$1/N$	Radyal temelli	Otomatik	35	Düzgün	Adam	Hiperbolik tanjant	(100,100)
Deney 7	500	Entropi	Sınırsız	$1/N$	Radyal temelli	Otomatik	5	Düzgün	Adam	ReLU	(100,)
Deney 8	300	Entropi	Sınırsız	$1/N$	Radyal temelli	Otomatik	23	Mesafeye bağlı	Adam	ReLU	(100,100)
Deney 9	100	Gini impuritesi	Sınırsız	$1/N$	Radyal temelli	Otomatik	35	Mesafeye bağlı	Adam	ReLU	(10,)
Deney 10	500	Entropi	Sınırsız	$1/N$	Radyal temelli	Otomatik	7	Düzgün	Adam	ReLU	(100,100)
Deney 11	300	Entropi	Sınırsız	$1/N$	Polinomiyal	Otomatik	33	Mesafeye bağlı	Adam	ReLU	(10,10)
Deney 12	500	Entropi	Sınırsız	$1/N$	Lineer	Otomatik	9	Düzgün	Adam	ReLU	(100,)
Deney 13	500	Entropi	Sınırsız	$1/N$	Polinomiyal	Otomatik	9	Düzgün	Adam	ReLU	(100,100)
Deney 14	300	Entropi	Sınırsız	$1/N$	Radyal temelli	Otomatik	7	Düzgün	Adam	ReLU	(100,)
Deney 15	100	Entropi	Sınırsız	$1/N$	Radyal temelli	Otomatik	33	Düzgün	Adam	Hiperbolik tanjant	(10,10)

Deney 16	100	Entropi	Sınırsız	$1/N$	Lineer	Otomatik	3	Düzgün	Adam	ReLU	(100,100)
Deney 17	100	Entropi	Sınırsız	$1/N$	Lineer	Otomatik	9	Düzgün	Adam	Hiperbolik tanjant	(100,)
Deney 18	200	Entropi	Sınırsız	$1/N$	Polinomiyal	Otomatik	31	Mesafeye bağlı	Adam	ReLU	(100,)
Deney 20	100	Gini impuritesi	Sınırsız	$1/N$	Lineer	Otomatik	9	Düzgün	Adam	ReLU	(100,)
Deney 21	200	Entropi	Sınırsız	$1/N$	Lineer	Otomatik	35	Mesafeye bağlı	Adam	ReLU	(100,)
Deney 22	500	Entropi	Sınırsız	$1/N$	Lineer	Otomatik	9	Düzgün	Adam	Lojistik sigmoid	(100,)
Deney 23	200	Entropi	Sınırsız	$1/N$	Polinomiyal	Otomatik	27	Mesafeye bağlı	Quasi-Newton	Hiperbolik tanjant	(100,)
Deney 24	200	Gini impuritesi	Sınırsız	$1/N$	Lineer	Otomatik	9	Mesafeye bağlı	Adam	Hiperbolik tanjant	(100,100)
Deney 25	500	Entropi	Sınırsız	$1/N$	Radyal temelli	Otomatik	3	Mesafeye bağlı	Adam	ReLU	(100,100)
Deney 26	200	Entropi	Sınırsız	$1/N$	Lineer	Otomatik	9	Düzgün	Adam	ReLU	(100,100)
Deney 28	300	Entropi	Sınırsız	$1/N$	Polinomiyal	Otomatik	7	Mesafeye bağlı	Adam	ReLU	(100,)
Deney 29	500	Entropi	Sınırsız	$1/N$	Radyal temelli	Otomatik	7	Mesafeye bağlı	Adam	ReLU	(100,100)
Deney 30	100	Gini impuritesi	Sınırsız	$1/N$	Lineer	Otomatik	5	Mesafeye bağlı	Adam	Lojistik sigmoid	(100,100)
Deney 31	500	Entropi	Sınırsız	$1/N$	Polinomiyal	Otomatik	33	Mesafeye bağlı	Adam	Hiperbolik tanjant	(100,)
Deney 32	300	Entropi	Sınırsız	$1/N$	Radyal temelli	Otomatik	7	Mesafeye bağlı	Adam	ReLU	(100,)
Deney 33	100	Entropi	Sınırsız	$1/N$	Polinomiyal	Otomatik	31	Düzgün	Adam	ReLU	(100,)
Deney 34	500	Entropi	Sınırsız	$1/N$	Polinomiyal	Otomatik	31	Mesafeye bağlı	Adam	ReLU	(100,)
Deney 35	200	Gini impuritesi	Sınırsız	$1/N$	Radyal temelli	Otomatik	7	Düzgün	Adam	ReLU	(100,)

Deney 36	100	Entropi	Sınırsız	$1/N$	Polinomiyal	Otomatik	5	Mesafeye bağlı	Adam	ReLU	(100,)
Deney 37	200	Gini impuritesi	Sınırsız	$1/N$	Radyal temelli	Otomatik	9	Düzgün	Adam	Hiperbolik tanjant	(10,)
Deney 38	100	Gini impuritesi	Sınırsız	$1/N$	Radyal temelli	Otomatik	7	Düzgün	Adam	Hiperbolik tanjant	(100,100)
Deney 39	200	Gini impuritesi	Sınırsız	$1/N$	Polinomiyal	Otomatik	7	Mesafeye bağlı	Adam	ReLU	(100,)

EK 5 Katılımcı-Bazında Veri Kümeleri 1 için Model Performansları

	Model	Öznitelik Seçimi: Yok	Öznitelik Seçimi: MI	Öznitelik Seçimi: PCA
Deney 2 k_{MI}**=60** k_{PCA}**=50**	RO	78,95 77,42	83,68 76,54	84,74 78,19
	SVM	77,37 74,90	75,26 75,89	77,37 74,25
	kNN	74,21 69,79	76,84 70,85	76,31 70,09
	YSA	77,89 76,77	73,68 75,25	77,37 75,37
Deney 3 k_{MI}**=20** k_{PCA}**=70**	RO	82,24 79,93	84,87 78,53	81,58 80,37
	SVM	76,97 79,19	75,00 75,68	69,08 78,17
	kNN	75,66 75,02	78,95 76,78	75,66 75,02
	YSA	78,95 78,39	76,97 75,02	76,31 77,65
Deney 4 k_{MI}**=60** k_{PCA}**=50**	RO	85,94 86,49	86,72 87,36	88,28 86,22
	SVM	88,28 85,79	89,06 86,48	87,50 86,13
	kNN	82,03 81,86	81,25 83,78	82,03 82,03
	YSA	85,94 87,88	86,72 88,23	87,50 88,67
Deney 5 k_{MI}**=70** k_{PCA}**=40**	RO	76,81 76,59	78,26 76,83	79,71 75,79
	SVM	72,46 75,14	71,01 75,38	74,64 72,80
	kNN	71,74 73,04	70,29 73,20	71,01 74,25
	YSA	75,36 76,84	78,26 77,48	78,98 78,13
Deney 6 k_{MI}**=70** k_{PCA}**=40**	RO	79,80 79,59	83,74 79,92	81,77 78,99
	SVM	77,34 79,43	78,82 78,61	80,29 77,56
	kNN	68,96 70,87	70,93 70,49	70,44 72,13
	YSA	79,80 78,77	76,85 78,39	79,80 79,38
Deney 7 k_{MI}**=20** k_{PCA}**=60**	RO	78,95 77,28	83,53 74,20	83,43 78,32
	SVM	74,85 76,69	75,29 70,52	78,11 76,48
	kNN	72,94 70,06	74,70 68,94	75,74 70,88
	YSA	77,65 77,41	70,59 71,77	75,74 75,43
Deney 8 k_{MI}**=70**	RO	83,33 78,83	84,37 79,97	82,29 76,71

k_{PCA}=70	SVM	77,08 77,54	81,25 79,97	78,12 79,97
	kNN	70,83 73,22	72,92 72,64	70,83 73,10
	YSA	82,29 78,92	80,21 78,58	81,25 80,58
Deney 9 **k_{MI}=20** **k_{PCA}=70**	RO	81,77 83,20	85,16 83,15	82,42 80,71
	SVM	85,71 81,07	83,42 81,11	82,32 82,03
	kNN	74,72 76,62	76,92 81,99	76,24 77,35
	YSA	82,87 81,54	84,61 82,60	86,26 81,81
Deney 10 **k_{MI}=60** **k_{PCA}=70**	RO	87,50 90,91	89,06 91,37	86,98 85,81
	SVM	85,42 87,09	85,94 87,32	86,46 88,30
	kNN	88,02 86,22	84,89 85,76	88,02 86,28
	YSA	91,67 90,21	90,62 90,39	89,06 90,50
Deney 11 **k_{MI}=50** **k_{PCA}=50**	RO	83,62 80,91	84,21 79,67	85,38 80,91
	SVM	83,04 81,11	80,70 80,85	81,29 74,05
	kNN	77,19 73,59	78,95 74,77	76,61 73,20
	YSA	81,87 76,21	77,78 75,95	86,55 79,21
Deney 12 **k_{MI}=50** **k_{PCA}=70**	RO	82,09 82,65	86,57 82,74	82,09 80,50
	SVM	82,09 80,50	82,96 81,57	71,85 76,28
	kNN	82,96 78,10	80,00 77,60	75,37 77,59
	YSA	79,10 80,99	78,36 82,74	81,48 82,31
Deney 13 **k_{MI}=50** **k_{PCA}=50**	RO	79,46 84,10	80,36 83,70	82,14 85,30
	SVM	79,46 83,20	79,46 83,20	79,46 83,80
	kNN	70,53 77,30	70,53 79,20	83,70 78,10
	YSA	78,57 84,30	79,46 85,00	79,46 83,50
Deney 14 **k_{MI}=40** **k_{PCA}=30**	RO	87,13 86,99	89,47 86,34	84,21 83,55
	SVM	88,89 86,80	88,89 87,19	87,13 86,34
	kNN	86,55 82,90	88,89 85,37	88,30 85,56
	YSA	88,89 87,12	91,23 86,86	90,64 87,19
Deney 15 **k_{MI}=40**	RO	77,44 78,45	81,10 77,84	77,44 77,36

k_{PCA}=50	SVM	78,53 77,81	79,87 76,34	78,53 76,85
	kNN	73,62 71,71	76,07 74,31	74,23 71,30
	YSA	77,44 76,82	82,93 77,57	76,83 76,27
Deney 16 **k_{MI}=50** **k_{PCA}=14**	RO	83,64 82,88	85,45 82,57	80,00 79,94
	SVM	75,45 80,55	76,36 79,74	70,00 76,49
	kNN	78,18 80,14	75,45 78,93	75,45 78,23
	YSA	81,82 82,48	84,54 83,99	82,73 80,65
Deney 17 **k_{MI}=50** **k_{PCA}=30**	RO	79,43 78,56	79,43 76,03	78,87 76,59
	SVM	82,39 78,78	78,17 75,88	80,85 78,17
	kNN	74,47 76,50	74,65 74,86	76,59 75,63
	YSA	80,28 77,85	74,47 71,76	77,46 77,06
Deney 18 **k_{MI}=50** **k_{PCA}=40**	RO	86,11 78,86	83,33 78,55	78,47 78,09
	SVM	75,69 79,95	77,78 77,31	75,69 72,18
	kNN	72,92 69,62	75,69 71,48	72,92 72,11
	YSA	84,03 79,80	80,55 78,94	80,55 80,11
Deney 20 **k_{MI}=70** **k_{PCA}=50**	RO	80,22 83,51	83,61 83,89	82,48 80,79
	SVM	80,22 81,50	85,87 81,29	85,31 81,54
	kNN	76,84 78,23	80,22 76,65	75,71 77,15
	YSA	83,05 82,38	87,00 82,74	84,18 83,05
Deney 21 **k_{MI}=73** **k_{PCA}=70**	RO	83,42 80,41	83,42 80,41	81,77 78,43
	SVM	83,98 79,85	83,98 79,85	75,69 74,68
	kNN	68,50 67,53	68,50 67,53	67,95 67,59
	YSA	82,87 81,39	82,87 81,39	85,08 80,84
Deney 22 **k_{MI}=60** **k_{PCA}=50**	RO	78,50 77,59	80,37 78,01	71,96 77,70
	SVM	75,70 78,22	76,63 77,80	76,63 78,85
	kNN	71,96 77,28	72,89 73,61	70,09 75,18
	YSA	71,96 77,38	76,63 77,69	70,09 75,71
Deney 23 **k_{MI}=60**	RO	82,68 78,14	82,68 78,23	77,16 78,49

k_{PCA}=70	SVM	76,38 79,10	77,16 79,63	77,95 79,19
	kNN	65,35 71,64	65,35 71,11	65,35 71,56
	YSA	77,16 77,44	75,59 76,91	74,01 80,16
Deney 24 **k_{MI}=40** **k_{PCA}=70**	RO	79,68 79,01	82,89 78,71	81,82 79,78
	SVM	72,73 74,84	72,73 72,87	75,40 74,96
	kNN	74,87 70,48	72,19 68,45	75,40 70,54
	YSA	83,42 78,77	78,07 72,69	84,49 80,38
Deney 25 **k_{MI}=40** **k_{PCA}=60**	RO	92,44 90,12	93,60 90,19	92,44 90,77
	SVM	91,28 90,06	93,02 88,83	91,28 89,99
	kNN	84,30 83,17	88,95 85,70	85,46 83,75
	YSA	96,51 91,23	94,77 91,29	93,60 91,94
Deney 26 **k_{MI}=70** **k_{PCA}=30**	RO	81,33 82,78	85,33 82,93	81,33 83,23
	SVM	88,00 82,93	88,00 83,98	80,00 78,73
	kNN	74,67 71,25	78,67 74,84	77,33 75,74
	YSA	86,67 85,02	93,33 83,53	88,00 83,83
Deney 28 **k_{MI}=20** **k_{PCA}=70**	RO	73,24 80,06	77,46 78,42	78,17 77,23
	SVM	76,76 78,02	72,53 72,13	74,65 77,63
	kNN	71,83 75,12	71,83 73,78	71,83 75,04
	YSA	75,35 79,75	79,57 76,61	78,87 80,30
Deney 29 **k_{MI}=70** **k_{PCA}=40**	RO	83,43 83,32	85,89 83,05	83,43 81,88
	SVM	82,21 78,81	80,37 78,26	76,69 78,13
	kNN	77,91 73,96	77,91 73,20	79,75 74,23
	YSA	88,34 81,27	88,34 82,77	87,12 83,05
Deney 30 **k_{MI}=70** **k_{PCA}=60**	RO	85,52 81,14	85,52 81,75	84,83 77,67
	SVM	81,38 74,90	82,07 74,59	77,24 75,13
	kNN	72,41 70,51	73,79 70,90	72,41 70,82
	YSA	82,76 78,91	86,90 81,14	84,83 81,29
Deney 31 **k_{MI}=60**	RO	86,39 82,49	89,00 82,49	83,77 81,61

k_{PCA}=60	SVM	83,25 79,80	83,77 78,28	82,72 78,46
	kNN	72,77 73,26	71,73 74,31	73,30 73,56
	YSA	83,77 80,39	81,15 78,98	84,29 82,43
Deney 32 **k_{MI}=60** **k_{PCA}=30**	RO	86,21 83,28	86,21 82,65	83,45 81,96
	SVM	81,94 81,76	82,07 81,42	86,21 82,26
	kNN	79,31 79,56	77,24 80,18	83,44 80,10
	YSA	82,07 82,18	79,31 81,26	80,00 81,57
Deney 33 **k_{MI}=20** **k_{PCA}=30**	RO	83,62 82,32	84,21 77,39	83,62 79,73
	SVM	85,96 81,29	74,27 74,33	77,19 78,49
	kNN	74,85 77,19	80,12 72,97	77,78 77,71
	YSA	80,70 80,31	78,36 76,93	81,29 79,21
Deney 34 **k_{MI}=40** **k_{PCA}=50**	RO	83,20 78,63	84,80 78,18	80,80 74,80
	SVM	79,20 77,47	80,80 76,04	80,00 77,29
	kNN	71,20 68,66	69,60 71,06	73,60 70,35
	YSA	76,80 78,09	83,20 77,91	80,80 76,49
Deney 35 **k_{MI}=40** **k_{PCA}=10**	RO	85,79 79,89	86,80 79,15	84,77 78,53
	SVM	82,74 77,85	84,77 77,90	82,23 75,98
	kNN	78,17 74,62	76,14 73,88	78,68 74,05
	YSA	82,23 78,98	83,25 78,19	79,19 76,03
Deney 36 **k_{MI}=50** **k_{PCA}=30**	RO	77,32 79,37	80,93 78,79	76,80 76,72
	SVM	79,38 77,59	75,26 75,75	70,62 73,22
	kNN	73,19 73,22	71,65 73,05	74,74 74,83
	YSA	80,41 78,45	74,23 78,79	81,96 78,16
Deney 37 **k_{MI}=40** **k_{PCA}=60**	RO	80,10 79,40	84,95 79,46	84,47 77,83
	SVM	77,67 78,81	76,70 74,90	79,61 78,16
	kNN	72,33 74,90	73,30 75,55	71,84 75,66
	YSA	80,58 79,78	73,79 78,59	83,01 80,87
Deney 38 **k_{MI}=50**	RO	90,40 86,30	88,38 86,70	86,36 82,30

k_{PCA}=20	SVM	86,87 85,85	89,39 83,82	88,89 84,72
	kNN	83,33 81,90	86,87 81,51	84,85 82,18
	YSA	89,90 86,30	88,89 85,46	88,89 84,16
Deney 39 **k_{MI}=30** **k_{PCA}=60**	RO	80,64 80,62	89,03 81,92	81,93 80,40
	SVM	80,00 80,91	83,22 81,41	81,93 81,27
	kNN	70,97 75,72	78,71 78,46	69,03 75,58
	YSA	81,29 84,36	78,71 81,48	80,64 82,85

EK 6 Katılımcı-Bazında Veri Kümeleri 2 için Model Performansları

	Model	Öznitelik Seçimi: Yok	Öznitelik Seçimi: MI	Öznitelik Seçimi: PCA
Deney 2 k_{MI}**=70** k_{PCA}**=40**	RO	89,80 85,44	89,80 85,11	91,26 86,73
	SVM	86,41 85,00	87,38 85,11	87,86 84,03
	kNN	83,01 80,56	83,98 80,56	85,44 80,83
	YSA	88,35 85,00	87,86 84,95	89,32 84,62
Deney 3 k_{MI}**=70** k_{PCA}**=70**	RO	92,02 93,01	92,64 93,08	93,86 91,57
	SVM	90,80 89,79	91,41 90,14	92,02 89,79
	kNN	82,21 78,29	79,75 78,70	82,21 78,36
	YSA	95,70 92,40	95,70 92,67	94,48 92,94
Deney 4 k_{MI}**=70** k_{PCA}**=14**	RO	93,55 92,87	95,16 92,69	90,32 89,80
	SVM	91,93 91,42	93,55 91,25	87,10 83,75
	kNN	85,48 87,28	86,29 86,82	85,48 87,28
	YSA	96,77 94,04	95,16 93,77	96,77 93,14
Deney 5 k_{MI}**=60** k_{PCA}**=60**	RO	86,39 85,16	88,43 84,55	86,39 83,71
	SVM	82,99 81,58	81,63 81,66	82,31 81,73
	kNN	74,15 74,89	72,11 74,96	74,15 75,34
	YSA	84,35 84,17	82,31 83,18	87,07 83,41
Deney 6 k_{MI}**=30** k_{PCA}**=60**	RO	83,17 85,45	85,15 85,39	85,15 85,06
	SVM	82,18 85,39	81,19 84,40	81,68 85,39
	kNN	74,75 75,19	77,23 78,00	75,25 75,58
	YSA	83,17 83,79	80,69 82,85	84,16 84,51
Deney 7 k_{MI}**=60** k_{PCA}**=50**	RO	83,78 86,65	85,94 86,53	85,40 84,90
	SVM	84,32 84,42	84,32 84,24	83,78 83,40
	kNN	76,22 78,86	76,22 78,74	75,67 79,11
	YSA	85,40 85,87	86,49 85,33	83,78 85,93
Deney 8 k_{MI}**=40**	RO	89,09 94,82	92,73 93,19	89,10 90,65

k_{PCA}=40	SVM	89,09 93,70	90,00 90,86	89,10 93,71
	kNN	71,82 75,10	71,01 80,18	74,54 78,25
	YSA	86,36 92,79	90,00 91,67	91,01 91,77
Deney 9 **k_{MI}=20** **k_{PCA}=70**	RO	89,42 90,03	90,86 90,25	89,90 88,80
	SVM	89,42 90,67	89,42 90,25	90,86 90,94
	kNN	81,25 81,08	87,98 87,08	81,25 81,14
	YSA	89,90 89,82	86,54 89,23	93,75 91,32
Deney 10 **k_{MI}=70** **k_{PCA}=50**	RO	95,63 97,19	96,12 97,03	91,75 93,52
	SVM	96,60 93,95	96,60 94,22	96,60 94,49
	kNN	91,75 90,55	94,17 90,76	92,23 90,06
	YSA	97,57 96,54	97,57 96,49	98,06 95,68
Deney 11 **k_{MI}=50** **k_{PCA}=70**	RO	86,86 87,15	86,86 86,96	88,00 88,36
	SVM	86,86 89,12	88,00 89,18	84,57 84,16
	kNN	76,57 78,24	79,43 78,50	76,57 78,31
	YSA	86,28 87,91	88,00 87,85	88,00 88,87
Deney 12 **k_{MI}=20** **k_{PCA}=73**	RO	86,88 88,77	89,34 88,04	86,06 87,60
	SVM	82,79 87,94	79,51 85,48	84,43 88,31
	kNN	77,87 80,73	80,33 82,74	73,77 80,91
	YSA	90,98 89,77	86,88 88,22	86,88 89,95
Deney 13 **k_{MI}=73** **k_{PCA}=30**	RO	91,18 92,30	91,18 92,30	90,44 89,60
	SVM	91,91 93,12	91,91 93,12	84,56 87,30
	kNN	83,09 80,01	83,09 80,01	80,88 82,56
	YSA	91,91 93,94	91,91 93,94	91,18 92,79
Deney 14 **k_{MI}=40** **k_{PCA}=70**	RO	96,51 96,30	96,51 96,69	96,51 94,15
	SVM	97,09 97,01	97,09 97,14	97,09 96,62
	kNN	89,53 91,23	92,44 94,28	89,53 91,43
	YSA	95,35 96,04	95,93 96,69	94,77 95,97
Deney 15 **k_{MI}=20**	RO	91,85 92,49	94,56 91,16	91,85 89,16

k_{PCA}=70	SVM	94,02 92,55	90,76 91,52	94,02 92,80
	kNN	77,72 78,09	85,33 86,02	77,72 77,97
	YSA	93,48 92,49	92,93 90,25	93,48 92,07
Deney 16 **k_{MI}=73** **k_{PCA}=50**	RO	89,65 91,69	89,65 91,69	89,65 91,69
	SVM	89,65 90,15	89,65 90,15	86,90 88,99
	kNN	86,21 86,91	86,21 86,91	86,90 87,22
	YSA	93,10 93,30	93,10 93,30	91,03 92,84
Deney 17 **k_{MI}=70** **k_{PCA}=30**	RO	90,17 91,74	90,17 91,28	90,17 90,12
	SVM	90,17 90,25	88,44 90,19	89,02 88,64
	kNN	81,50 81,86	83,81 83,28	86,13 84,44
	YSA	91,33 90,12	89,59 90,45	89,59 88,25
Deney 18 **k_{MI}=50** **k_{PCA}=50**	RO	88,89 90,79	90,64 89,94	85,38 88,37
	SVM	90,64 89,35	92,98 88,96	79,53 80,66
	kNN	73,10 76,74	80,12 78,70	76,02 77,72
	YSA	88,30 90,00	89,47 89,88	92,40 90,40
Deney 20 **k_{MI}=20** **k_{PCA}=73**	RO	89,11 92,20	91,09 91,04	93,56 91,60
	SVM	90,10 91,26	85,64 87,62	90,10 91,26
	kNN	86,63 81,81	88,61 86,62	86,63 81,81
	YSA	88,61 93,20	90,10 90,32	94,06 94,31
Deney 21 **k_{MI}=30** **k_{PCA}=60**	RO	89,42 88,76	89,95 89,29	87,30 88,59
	SVM	85,71 87,12	83,07 84,88	84,13 87,12
	kNN	77,25 75,41	80,95 80,88	76,72 75,65
	YSA	88,89 89,53	89,42 88,70	91,53 90,59
Deney 22 **k_{MI}=40** **k_{PCA}=60**	RO	94,26 88,08	96,72 87,35	91,80 88,63
	SVM	90,16 89,92	89,34 87,99	86,88 89,37
	kNN	81,97 78,92	85,24 81,12	81,97 79,65
	YSA	90,16 89,09	89,34 87,81	89,34 88,27
Deney 23 **k_{MI}=30**	RO	80,16 84,22	84,30 82,75	84,30 82,84

k_{PCA}=50	SVM	87,60 83,58	80,16 80,90	74,38 77,40
	kNN	71,90 70,57	72,73 75,18	73,55 72,79
	YSA	81,82 84,59	82,64 82,28	85,12 83,85
Deney 24 **k_{MI}=73** **k_{PCA}=70**	RO	83,42 86,14	83,42 86,14	84,97 85,68
	SVM	74,09 83,89	74,09 83,89	74,09 83,66
	kNN	76,16 78,00	76,16 78,00	76,16 77,89
	YSA	80,31 85,22	80,31 85,22	83,94 85,57
Deney 25 **k_{MI}=40** **k_{PCA}=30**	RO	95,45 95,37	98,05 94,36	94,80 93,20
	SVM	97,40 94,36	96,75 94,36	95,45 94,00
	kNN	91,56 89,80	91,56 91,25	92,86 91,47
	YSA	97,40 95,44	96,10 95,31	94,80 94,29
Deney 26 **k_{MI}=40** **k_{PCA}=60**	RO	85,29 85,27	91,18 84,78	86,76 82,81
	SVM	89,70 82,81	91,18 81,67	91,18 83,47
	kNN	75,00 75,78	75,00 75,62	77,94 75,61
	YSA	83,82 86,90	89,70 83,96	88,23 86,90
Deney 28 **k_{MI}=30** **k_{PCA}=14**	RO	94,15 90,77	94,74 91,09	91,81 88,36
	SVM	93,57 90,05	92,98 89,47	88,30 85,83
	kNN	80,12 82,58	85,96 83,88	84,21 84,79
	YSA	94,74 91,29	93,57 89,01	92,40 89,34
Deney 29 **k_{MI}=60** **k_{PCA}=73**	RO	87,50 89,11	89,88 89,31	91,67 87,72
	SVM	89,28 89,24	90,48 88,91	91,07 89,37
	kNN	78,57 80,28	79,76 80,54	78,57 80,28
	YSA	91,67 89,38	91,67 89,38	91,67 90,77
Deney 30 **k_{MI}=40** **k_{PCA}=60**	RO	87,04 89,06	88,89 88,86	88,27 88,79
	SVM	86,42 87,41	83,33 87,41	85,18 87,48
	kNN	70,99 79,09	80,25 83,22	72,22 79,58
	YSA	88,89 87,55	84,57 88,24	86,42 87,48
Deney 31 **k_{MI}=30**	RO	81,46 84,10	82,58 84,66	87,08 84,91

k_{PCA}=70	SVM	83,15 84,10	78,65 80,53	77,53 81,28
	kNN	76,97 79,40	75,84 77,71	78,09 79,46
	YSA	83,15 83,59	79,77 82,15	83,71 83,84
Deney 32 **k_{MI}=40** **k_{PCA}=20**	RO	84,67 88,30	86,00 87,63	90,67 88,74
	SVM	92,00 89,48	85,33 86,89	90,67 89,04
	kNN	80,67 85,78	81,33 84,30	84,67 87,48
	YSA	92,67 90,81	86,00 87,78	90,67 88,74
Deney 33 **k_{MI}=30** **k_{PCA}=70**	RO	90,62 83,92	90,62 83,02	91,25 83,79
	SVM	93,12 85,59	89,37 83,16	89,37 80,86
	kNN	77,50 75,43	81,25 77,31	77,50 75,57
	YSA	91,87 86,29	91,25 84,69	95,62 87,48
Deney 34 **k_{MI}=73** **k_{PCA}=20**	RO	92,36 91,82	92,36 91,82	91,67 90,20
	SVM	90,97 90,97	90,97 90,97	87,50 87,65
	kNN	76,39 78,62	76,39 78,62	82,64 81,71
	YSA	89,58 92,67	89,58 92,67	87,50 91,74
Deney 35 **k_{MI}=73** **k_{PCA}=20**	RO	86,80 89,11	86,80 89,11	87,31 87,24
	SVM	83,25 87,75	83,25 87,75	81,22 86,00
	kNN	80,71 82,54	80,71 82,54	84,77 81,91
	YSA	85,28 88,03	85,28 88,03	82,74 86,56
Deney 36 **k_{MI}=50** **k_{PCA}=30**	RO	92,86 89,63	92,86 89,92	90,31 88,61
	SVM	91,84 89,92	90,31 86,16	85,20 83,43
	kNN	87,24 84,11	87,75 84,11	88,77 85,71
	YSA	93,37 90,66	92,35 89,18	95,41 90,03
Deney 37 **k_{MI}=73** **k_{PCA}=20**	RO	91,22 88,61	91,22 88,61	89,27 88,50
	SVM	90,73 89,80	90,73 89,80	90,73 88,66
	kNN	85,85 85,09	85,85 85,09	88,78 85,79
	YSA	91,71 88,66	91,71 88,66	88,78 88,07
Deney 38 **k_{MI}=20**	RO	92,19 94,36	93,23 93,19	91,67 91,97

k_{PCA}=40	SVM	92,19 94,36	92,71 93,48	92,71 94,30
	kNN	88,02 92,26	90,62 93,02	90,10 92,09
	YSA	94,79 94,71	95,83 94,53	96,35 93,72
Deney 39 **k_{MI}=60** **k_{PCA}=50**	RO	83,78 83,67	84,46 83,75	83,78 82,54
	SVM	83,78 83,44	85,13 83,60	82,43 79,16
	kNN	81,08 79,91	79,73 80,21	81,08 79,31
	YSA	85,13 85,18	81,76 84,27	84,46 85,18