



MINISTERUL EDUCAȚIEI ȘI CERCETĂRII  
UNIVERSITATEA NAȚIONALĂ DE ȘTIINȚĂ ȘI TEHNOLOGIE  
POLITEHNICA BUCUREȘTI



Școala Doctorală de Electronică, Telecomunicații  
și Tehnologia Informației

# REZUMAT TEZĂ DE DOCTORAT

**Ing. Sama Hussein AL-GBURI**

---

CONTRIBUȚII LA DETECTAREA STĂRII DE  
OBOSEALĂ A ȘOFERILOR: UN CADRU  
MULTIMODAL INTEGRAND EEG, PRELUCRARE  
DE IMAGINI, ȘI ÎNVĂȚARE AUTOMATĂ

CONTRIBUTIONS TO DRIVER DROWSINESS  
DETECTION: A MULTIMODAL FRAMEWORK  
INTEGRATING EEG, IMAGE PROCESSING, AND  
MACHINE LEARNING

---

**Prof. Dr. Ing. Ion MARGHESCU**  
Univ. Politehnica din București

Conducător de doctorat

**BUCUREȘTI 2025**

---



# Conținut

Chapter 1	Introducere .....	1
1.1	Problemă, obiective și contribuții de cercetare .....	1
1.1.1	Obiectivele cercetării .....	2
1.2	Domeniile de cercetare .....	2
1.3	Conținutul tezei .....	2
Chapter 2	Stadiul actual al detectării somnolenței șoferului .....	4
2.1	Lucrări conexe .....	4
2.2	Concluziile capitolului .....	4
3.1	Descrierea seturilor de date .....	5
3.1.1	Set de date EEG .....	5
3.1.2	Seturi de date video: .....	5
3.2	Evaluarea modelelor de învățare automată pentru detectarea somnolenței șoferului folosind EEG din setul de date TRYOUT .....	5
3.3	Linia de bază preliminară și motivația CNN .....	6
3.4	Evaluarea arhitecturilor CNN avansate pe SUST-DDD .....	6
3.5	Concluziile capitolului .....	6
Chapter 4	Detectarea și clasificarea somnolenței șoferului: de la analiza datelor EEG la evaluarea performanței modelului utilizat .....	7
4.1	Detectarea integrată a somnolenței șoferului bazată pe EEG: prelucrarea datelor și evaluarea modelului .....	7
4.2	Vă prezentăm un nou model FNCA+DNN pentru detectarea îmbunătățită a somnolenței șoferului .....	8
4.2.1	Rezultate și analiză .....	9
4.3	Arhitectură îmbunătățită FNCA+DNN pentru detectarea somnolenței șoferului folosind semnale EEG .....	10
4.3.1	Comparație cu metodele de ultimă generație privind setul de date SEED-VIG .....	11
4.4	Concluziile capitolului .....	11
Chapter 5	EFFRES-DROWSYNET: UN NOU MODEL HIBRID CARE UTILIZEAZĂ EFFICIENTNET-B0 ȘI RESNET-50 PENTRU DETECTAREA SOMNOLENȚEI ȘOFERULUI .....	13
5.1	Preprocesarea datelor, extragerea caracteristicilor și implementarea modelului hibrid .....	13

5.2	Evaluarea performanței EFFRES-DrowsyNet în diferite epoci de antrenament pe setul de date SUST-DDD.....	15
5.2.1	Analiza performanței antrenamentului modelului (cu 40 de epoci și oprire timpurie la epoca 25) pe setul de date SUST-DDD .....	17
5.2.2	Compararea modelului de învățare profundă hibrid propus cu modelele existente. ....	17
5.3	Evaluarea performanței EFFRES-DrowsyNet în diferite epoci de antrenament pe setul de date YawDD .....	18
5.3.1	Analiza performanței antrenamentului modelului (cu 70 de epoci și oprire timpurie la Epoca 38) pe setul de date YawDD.....	18
5.4	Detectarea somnolenței în timp real folosind EffRes-DrowsyNet .....	19
5.5	Concluziile capitolului .....	20
Chapter 6	Concluzii și lucrări viitoare.....	21
6.1	Rezultatele cercetării și contribuțiile .....	21
6.2	Lista publicațiilor originale.....	25
6.3	Lucrări viitoare.....	27
	Referințe .....	28

# Capitolul 1 Introducere

Accidentele sunt evenimente imprevizibile care pot duce la vătămări fizice și emoționale grave. În timp ce majoritatea șoferilor nu intenționează să provoace accidente, eroarea umană rămâne principala cauză. Factorii care contribuie includ distragerea atenției, consumul de alcool, viteza, ignorarea semnalelor de circulație și somnolența. Oboseala șoferului, în special, este o cauză majoră a accidentelor rutiere la nivel mondial, ceea ce a determinat cercetări ample privind sistemele de detectare și alertă. De exemplu, studiul folosește o abordare hibridă folosind semnale EEG și ECG din baza de date DROZY pentru a evalua cu precizie nivelurile de somnolență.[1][2, 3][4]

Comportamentul la volan joacă un rol crucial în siguranța rutieră și impactul asupra mediului. La nivel global, accidentele rutiere sunt a 19-a cauză principală de deces. Pentru a rezolva acest lucru, au fost dezvoltate sisteme inteligente de transport (ITS) pentru a monitoriza șoferii și a reduce incidentele. Recent, învățarea profundă a fost aplicată din ce în ce mai mult pentru a analiza comportamentul de conducere, permițând sisteme avansate de asistență a șoferului care oferă feedback personalizat și sporesc siguranța prin detectarea și atenuarea comportamentelor riscante.[5][6][7]

## 1.1 Problemă, obiective și contribuții de cercetare

Somnolența șoferului este un factor semnificativ în accidentele rutiere la nivel global. Sistemele convenționale de monitorizare, deși benefice, sunt adesea insuficiente în ceea ce privește acuratețea, capacitatea de răspuns în timp real și adaptabilitatea la diferite condiții de conducere. Această teză propune un cadru de detectare multimodală care combină semnalele fiziologice (EEG) cu indicii comportamentale bazate pe imagini, utilizând tehnici avansate de învățare automată și învățare profundă. Scopul este de a dezvolta un sistem fiabil, interpretabil și capabil în timp real pentru detectarea eficientă a somnolenței.

Pentru a realiza acest lucru, cercetarea este structurată în jurul a patru întrebări cheie de cercetare, fiecare aliniată cu capitole experimentale specifice și contribuții științifice, așa cum este subliniat în tabelul 1.1.

***Masă 1.1** Principalele întrebări și contribuții de cercetare.*

Nu.	Întrebare de cercetare (RQ)	Tip de contribuție
RQ1	Cum pot fi analizate și preprocesate în mod sistematic seturile de date EEG și video pentru a evalua performanța diferitelor modele de învățare automată și de învățare profundă în detectarea somnolenței șoferului?	Evaluarea seturilor de date și analiza comparativă a modelelor.
RQ2	Cum pot fi optimizate caracteristicile bazate pe EEG folosind analiza rapidă a componentelor de vecinătate și învățarea profundă pentru a îmbunătăți acuratețea și eficiența detectării somnolenței șoferului?	Optimizarea caracteristicilor și integrarea învățării profunde

RQ3	Cum poate o arhitectură hibridă de învățare profundă bazată pe procesarea imaginilor să îmbunătățească detectarea în timp real a somnolenței șoferului în condiții reale?	Îmbunătățirea învățării profunde bazate pe viziune
RQ4	Cum se compară modelele propuse cu metodele de ultimă generație existente în ceea ce privește indicatorii de performanță și robustețea seturilor de date de referință?	Evaluare experimentală și comparație a performanței

### 1.1.1 Obiectivele cercetării

Obiectivele cheie ale acestei teze aliniate la întrebările de cercetare de mai sus sunt:

- Investigarea și evaluarea modalităților de date existente (semnale EEG și video facial) în scopul detectării somnolenței șoferului.
- Explorarea și compararea diferitelor abordări tradiționale de învățare automată și învățare profundă pentru a identifica strategii de modelare adecvate pentru clasificarea stării comportamentale.
- Să proiecteze conducte de învățare eficiente adaptate fiecărei modalități, îmbunătățind reprezentarea caracteristicilor și acuratețea clasificării.
- Să dezvolte și să valideze cadre robuste de detectare a somnolenței folosind seturi de date de referință, asigurând generalizabilitatea și performanța în diferite condiții experimentale.
- Să contribuie la avansarea sistemelor multimodale de monitorizare a conducătorilor auto prin furnizarea de perspective comparative și implementări practice.

## 1.2 Domeniile de cercetare

- Concentrați-vă pe clasificarea somnolenței folosind învățarea profundă.
- Utilizați mai multe seturi de date de referință din studiile anterioare.
- Implementați și analizați modelul propus folosind Python.
- Acuratețea este principala măsură de performanță.

## 1.3 Conținutul tezei

Capitolul 1 introduce studiul, evidențiază importanța detectării somnolenței, precizează problema, obiectivele și domeniul de aplicare al cercetării și trece în revistă comportamentul și provocările.

Capitolul 2 analizează metodele de monitorizare a atenției și de detectare a oboselii, seturile de date și sistemele bazate pe inteligență artificială folosind WBAN.

Capitolul 3 descrie seturile de date utilizate, evaluează modelele ML pe EEG și date video, explică extragerea caracteristicilor, preprocesarea și performanța.

Capitolul 4 acoperă preprocesarea EEG, analiza spectrală, etichetarea datelor, modelele tradiționale și introduce modelul FNCA-DNN.

Capitolul 5 dezvoltă un model hibrid, EFFRES-DrowsyNet, folosind EfficientNetB0 și ResNet50 pe seturile de date SUST-DDD și YawDD, cu detectarea reperelor și analiza EAR/MAR.

Capitolul 6 încheie cercetarea, rezumă contribuțiile, activitatea de diseminare și prezintă lucrările viitoare.

# Capitolul 2 Stadiul actual al detectării somnolenței șoferului

Serviciile de transport necesită tehnologii avansate, cum ar fi sistemele inteligente de transport (ITS) pentru o gestionare îmbunătățită a traficului, informații îmbunătățite despre călătorii și rețele de transport mai sigure. În ciuda importanței lor în viața modernă, sistemele de transport actuale se confruntă cu provocări care trebuie dezvoltate pentru a asigura o mai bună furnizare a serviciilor. [8]

Acest capitol prezintă o revizuire sistematică a literaturii, subliniind metodologia și criteriile de căutare utilizate pentru a identifica studiile relevante. Cincisprezece studii au îndeplinit criteriile de includere după revizuirea literaturii din baze de date electronice precum IEEE și Science Direct. Capitolul discută, de asemenea, despre sistemele de monitorizare a feței șoferului pentru evaluarea stării fizice și mentale a șoferilor prin analiza imaginii faciale, urmată de o prezentare generală a simptomelor legate de distragere și oboseală.

## 2.1 Lucrări conexe

Somnolența este o stare de oboseală care poate apărea în timpul activităților critice, cum ar fi conducerea și poate duce la consecințe care pun viața în pericol. Este cauzată în primul rând de oboseală, ceea ce duce la reducerea atenției și întârzierea timpului de reacție. Al-Gburi et al. a evidențiat lipsa unei definiții clare a oboselii și a propus metode precum rata de clipire a ochilor și scala de somnolență Karolinska. Sikander și Anwar au clasificat tehnicile de detectare în cinci grupuri și au subliniat caracteristicile domeniului frecvenței pentru detectarea bazată pe EEG. [9] [10][3][11]

## 2.2 Concluziile capitolului

Capitolul 2 a oferit o trecere în revistă cuprinzătoare a conceptelor fundamentale, metodologiilor și progreselor tehnologice în detectarea somnolenței șoferului. A examinat diverse definiții de oboseală și scale de măsurare, de la evaluări bazate pe EEG la recunoaștere facială și rețele wireless de zonă a corpului, evidențiind natura multidisciplinară a monitorizării atenției. Revizuirea sistematică a studiilor recente și a sistemelor de experți a subliniat creșterea rapidă a procesării imaginilor, a analizei semnalelor fiziologice și a abordărilor bazate pe inteligență artificială în abordarea oboselii șoferului. Au fost identificate tendințe cheie, cum ar fi integrarea multimodală și trecerea la monitorizarea în timp real, non-intruzivă. Aceste perspective oferă o bază teoretică solidă și informează direct cadrele experimentale dezvoltate în capitolele următoare.



# Capitolul 3 Evaluarea seturilor de date de referință și a modelelor de învățare în detectarea somnolenței conducătorilor auto

## 3.1 Descrierea seturilor de date

### 3.1.1 Set de date EEG

- Cel **TRYOUT** include înregistrări de la trei participanți în patru condiții de conducere: Odihnă-Automată, Odihnă-Manuală, Obositoare-Automată și Obositoare-Manuală. [12]
- Un **Set de date EEG cu 40 de canale** arhivat pe Figshare oferă înregistrări de la doisprezece subiecți în stări de odihnă și oboseală folosind un sistem de amplificare Neuroscan.[13]
- Un **set de date EEG în stare de repaus** de la OpenNeuro include date de la 71 de participanți evaluați în timpul somnului normal și privarea de somn.[14]
- Cel **Setul de date SEED-VIG** [15] oferă EEG, EOG și date de urmărire oculară sincronizate înregistrate în timpul condusului simulat.

### 3.1.2 Seturi de date video:

- Cel **Setul de date SUST-DDD** [16] conține 2.074 de videoclipuri de conducere din lumea reală (975 somnoroși, 1.099 nu somnoroși) înregistrate de 19 șoferi în medii naturale.
- Cel **Setul de date YawDD** [17], constă din 351 de înregistrări video adnotate în vehicul axate pe detectarea căscatului. [18]

## 3.2 Evaluarea modelelor de învățare automată pentru detectarea somnolenței șoferului folosind EEG din setul de date TRYOUT

Această secțiune evaluează performanța modelelor tradiționale de învățare automată pentru clasificarea somnolenței șoferului folosind date EEG din setul de date TRYOUT, care include înregistrări de la trei șoferi în patru condiții de conducere distincte. Pentru a gestiona dimensiunea setului de date și a menține consecvența, datele

fiecărui subiect au fost limitate la 120.000 de rânduri și a fost pregătit un set de date combinat de 270.000 de eșantioane pentru antrenament și evaluare.[12] Preprocesarea a implicat manipularea valorilor lipsă folosind imputarea și codificarea variabilelor categorice. Patru modele de învățare automată, Regresie logistică, Support Vector Machine (SVM), Gradient Boost și Random Forest, au fost implementate și evaluate folosind acuratețea, precizia, reamintirea și scorul F1. Dintre aceste modele, Random Forest a demonstrat cea mai consistentă și fiabilă performanță de clasificare în toate scenariile de conducere, obținând cea mai mare precizie generală. Aceste rezultate stabilesc o bază practică pentru detectarea somnolenței bazată pe EEG și susțin rolul său ca metodă comparativă în experimentele ulterioare care implică abordări mai avansate de învățare profundă.[19]

### **3.3 Linia de bază preliminară și motivația CNN**

Un CNN inițial ușor a fost implementat pe setul de date SUST-DDD pentru a stabili o linie de bază pentru detectarea somnolenței. În timp ce modelul a atins o precizie de antrenament de 95,66%, a arătat semne de supraajustare, acuratețea validării atingând un vârf de 87,58%. Aceste rezultate au evidențiat nevoia de arhitecturi mai avansate cu o generalizare mai bună, motivând utilizarea EfficientNetB0 și ResNet50 în secțiunile ulterioare.

### **3.4 Evaluarea arhitecturilor CNN avansate pe SUST-DDD**

Pentru a îmbunătăți detectarea somnolenței, au fost evaluate două modele convoluționale avansate: EfficientNetB0 și ResNet50. Ambele au fost adaptate pentru imagini faciale în tonuri de gri și antrenate pe setul de date SUST-DDD folosind creșterea standard a datelor, oprirea timpurie și programarea ratei de învățare. EfficientNetB0 a obținut o precizie de 96,79%, o precizie de 95,91% și o rechemare de 97,75%, în timp ce ResNet50 a obținut o acuratețe de 96,42%, o precizie de 96,03% și o rechemare de 96,83%. Aceste rezultate demonstrează că ambele modele captează în mod eficient indiciile vizuale asociate cu oboseala șoferului. Performanța lor ridicată și punctele forte complementare au motivat integrarea lor într-o arhitectură hibridă, EffRes-DrowsyNet, introdusă în capitolul 5.

### **3.5 Concluziile capitolului**

Acest capitol a abordat RQ1 prin explorarea abordărilor bazate pe EEG și video pentru detectarea somnolenței șoferului folosind diverse seturi de date. Caracteristicile cheie ale EEG au inclus benzi alfa și beta, în timp ce datele video au oferit indicii pentru ochi și gură. Random Forest a avut cele mai bune rezultate pentru EEG, iar CNN-urile au fost eficiente pentru video. Strategiile de preprocesare au ajutat la abordarea zgomotului, dezechilibrului și supraajustării. Aceste rezultate formează baza pentru modelele hibride introduse în capitolul următor.

# Capitolul 4 Detectarea și clasificarea somnolenței șoferului: de la analiza datelor EEG la evaluarea performanței modelului utilizat

Somnolență, o stare între veghe și somn, împărtășește modelele EEG cu oboseala, dar este mai pronunțată cu odihna. Prezintă riscuri de siguranță, în special pentru cei cu vârste cuprinse între 15 și 29 de ani, prin afectarea cogniției și a timpului de reacție. În ciuda provocărilor semnal-zgomot scăzute, EEG este un instrument fiabil pentru detectarea timpurie a oboselii. Acest capitol prezintă un cadru care utilizează preprocesarea EEG, analiza spectrală a lui Welch și clasificarea în stări de alertă, intermediare sau somnoroasă.[20][21][22]

## 4.1 Detectarea integrată a somnolenței șoferului bazată pe EEG: prelucrarea datelor și evaluarea modelului

Această secțiune prezintă un cadru de detectare a somnolenței șoferului bazat pe EEG care implică preprocesarea, extragerea caracteristicilor și clasificarea folosind modele tradiționale ML și DNN. Acesta evaluează performanța modelului atât în setări multiclase, cât și binare, folosind seturi de date EEG specifice subiectului și de referință.

### Preprocesarea EEG și extragerea caracteristicilor

Semnalele EEG au fost segmentate și procesate folosind metoda lui Welch pentru a extrage caracteristicile benzii alfa (8-13 Hz) și beta (13-30 Hz) - indicatori comuni ai vigilenței. Caracteristicile au fost normalizate și etichetate în stări cognitive: Alertă, Intermediară și Somnolență, permițând o analiză spectrală consistentă pentru antrenarea clasificatorului.

### Clasificare multiclasă: Set de date TRYOUT

Datele EEG din setul de date TRYOUT (patru condiții de conducere) au fost utilizate pentru a evalua cinci clasificatori: Regresie logistică, Pădure aleatorie, SVM, Gradient Boost și DNN. După echilibrarea setului de date, Random Forest a obținut cea mai mare precizie (78,57%), urmată de Gradient Boosting și Logistic Regression. DNN a arătat performanțe moderate, în timp ce SVM a avut cele mai slabe performanțe.

### Clasificare binară: set de date EEG specific subiectului

A fost utilizat un set de date EEG cu 40 de canale de la doisprezece subiecți sănătoși, etichetat ca Alert sau Drowsy pe baza rapoartelor alfa/beta și a votului majoritar. Random Forest a condus din nou cu o acuratețe de 94%, urmată de DNN (88%) și Regresie logistică (83%), confirmând eficacitatea sa în seturile de date. Masă 4.1 rezumă rezultatele.

*Masă 4.1 Rezultatele simulării diferitelor modele.*

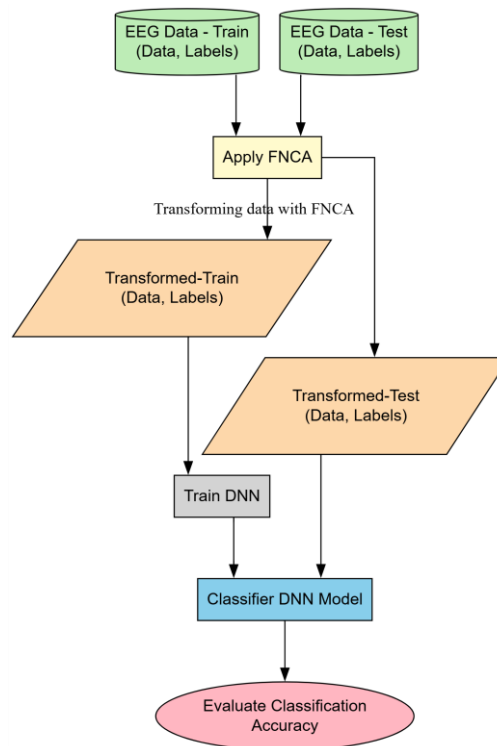
Model	Precizie	Precizie	Aminti	Scor F1
<b>Pădure aleatorie</b>	78.57% / 94%	78.46% / 94%	78.57% / 94%	77.58% / 94%
Amplificarea gradientului	77.86%	77.39%	77.86%	77.17%
Regresie logistică	77.14% / 83%	76.78% / 83%	77.14% / 83%	75.96% / 83%
DNN	72.86% / 88%	73.02% / 88%	72.86% / 88%	72.88% / 88%
SVM	71.43%	70.44%	71.43%	67.74%

Notă: Prima valoare = Multiclasă (TRYOUT), A doua valoare = Binar (EEG cu 12 subiecți).

Aceste descoperiri evidențiază performanța puternică a modelelor de ansamblu - în special Random Forest - în clasificarea somnolenței bazată pe EEG în diverse seturi de date. Capacitatea lor de generalizare oferă o bază solidă pentru modelul avansat FNCA+DNN introdus în secțiunea următoare.

## 4.2 Vă prezentăm un nou model FNCA+DNN pentru detectarea îmbunătățită a somnolenței șoferului

Această secțiune introduce un model hibrid care combină analiza rapidă a componentelor de vecinătate (FNCA) cu o rețea neuronală profundă (DNN) pentru a îmbunătăți detectarea somnolenței bazată pe EEG. FNCA este aplicat pentru a reduce dimensionalitatea caracteristicilor, transformând spațiul caracteristicilor pentru a îmbunătăți separabilitatea claselor înainte de clasificarea de către DNN. Arhitectura DNN include straturi de intrare potrivite cu caracteristicile FNCA, straturi ascunse cu activări ReLU și o ieșire Softmax pentru clasificare (Cifra 4.1). Instruirea a folosit optimizatorul Adam cu rata de învățare și reglarea dimensiunii lotului.



**Cifră 4.1** Diagrama bloc pentru DNN+FNCA.

#### 4.2.1 Rezultate și analiză

Modelul FNCA+DNN a arătat un comportament puternic de învățare în timpul simulărilor MATLAB. Începând cu 33,59% mini-lot și 45,86% acuratețe de validare, performanța s-a îmbunătățit semnificativ până în epoca 15, ajungând la 81,25% și, respectiv, 80,88%. Până în epoca 30, acuratețea mini-lotului a crescut la 86,72% și acuratețea validării la 83,67%, cu pierderi scăzând de la 28,37 la 0,30, acuratețea și tendințele pierderilor stabilizate între epocile 15-30, cu o supraajustare minimă, susținută de o rată de învățare de bază constantă de 0,0010.

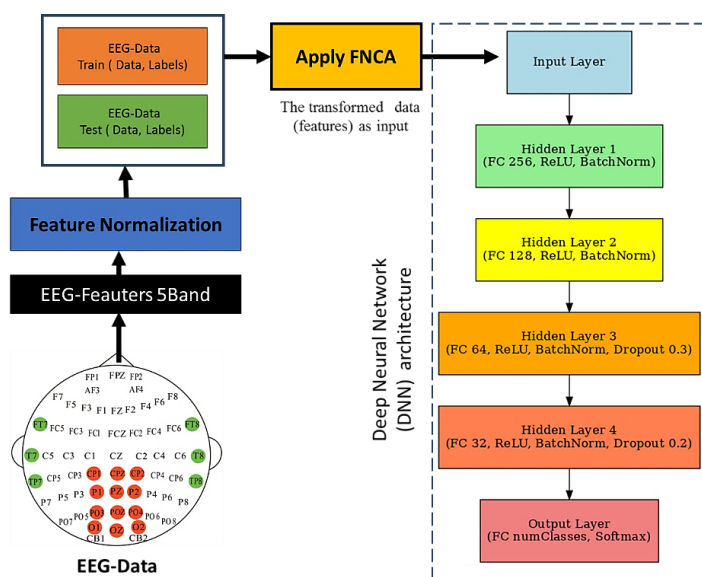
**Masă 4.2** Rezultatele simulării pentru 4 experimente diferite.

Rata de învățare	Epoci	Precizia mini-lotului	Acuratețea validării
0.0010	30	86.72%	83.67%
0.0010	50	88.28%	83,59%)
0.0010	40	89.84%	82.80%
0.010	30	81.25%	81,43%

Pe scurt, DNN-ul integrat FNCA arată performanțe puternice, cu o precizie în creștere și pierderi în scădere de-a lungul epocii de antrenament, evidențiind eficacitatea transformării caracteristicilor FNCA. Lucrările viitoare ar putea explora reglarea ratei de învățare, testarea arhitecturilor mai profunde sau utilizarea funcțiilor alternative de activare pentru a îmbunătăți și mai mult performanța.


### 4.3 Arhitectură îmbunătățită FNCA+DNN pentru detectarea somnolenței șoferului folosind semnale EEG

Cifra 4.2 prezintă modelul îmbunătățit FNCA+DNN pentru detectarea somnolenței șoferului bazată pe EEG. Conducța include preprocesarea EEG, normalizarea caracteristicilor și FNCA pentru rafinarea caracteristicilor. Arhitectura DNN are un strat de intrare urmat de patru straturi complet conectate (256, 128, 64, 32 neuroni) cu activări ReLU, normalizare în lot și abandon (0,3, 0,2) pentru a îmbunătăți stabilitatea și a preveni supraajustarea. Un strat de ieșire Softmax clasifică stările ca alertă sau somnoroasă. Canalele cheie EEG sunt vizualizate printr-o hartă a electrozilor. Deși nu au fost efectuate studii de ablație, designul modelului urmează practici dovedite de învățare profundă EEG pentru a îmbunătăți generalizarea și robustețea.[23, 24]



**Cifra 4.2** Un model FNCA-DNN îmbunătățit pentru detectarea somnolenței șoferului folosind semnale EEG.

Arhitectura îmbunătățită FNCA+DNN îmbunătățește acuratețea clasificării, reducând în același timp supraechiparea. Dispune de straturi complet conectate (256, 128, 64, 32 de neuroni) cu activare ReLU, normalizare în lot și straturi Dropout (30% și 20%) pentru regularizare. Un strat de ieșire Softmax efectuează clasificarea binară. Modelul a fost evaluat folosind setul de date SEED-VIG, dezvoltat de Laboratorul BCMI al Universității Jiao Tong din Shanghai, care include date EEG și EOG de la 23 de participanți în timpul conducerii simulate folosind 17 canale EEG (sistem 10-20, eșantionare de 200 Hz). Ochelarii de urmărire a ochilor au furnizat etichetarea vigilenței bazată pe PERCLOS. După cum se arată în [15]Cifra 4.3, modelul FNCA + DNN a obținut o precizie medie de  $\sim 90\% \pm 0,06$  în datele EEG de la 21 de subiecți, mai mulți depășind o acuratețe de 97% și câțiva în jur de 86%, probabil din cauza variabilității EEG sau a zgomotului. Aceste rezultate confirmă robustețea și eficacitatea modelului în detectarea somnolenței la indivizi.



*Cifra 4.3 Rezultatele modelului propus aplicat pentru diferite subiecte.*

### 4.3.1 Comparație cu metodele de ultimă generație privind setul de date SEED-VIG

Masă 4.3 arată că modelul propus FNCA+DNN depășește metodele recente din setul de date SEED-VIG, obținând o precizie de  $94,29\% \pm 0,0028$  cu 12 subiecți și  $90,83\% \pm 0,0012$  cu 21 de subiecți. În comparație cu alte metode (precizie de 80-87%), FNCA+DNN demonstrează extragerea și generalizarea caracteristicilor EEG superioare pentru detectarea somnolenței șoferului.

*Masă 4.3 Comparație de acuratețe pe setul de date SEED-VIG pentru FNCA+DNN și metode recente.*

Referință	An	Clasificator	Precizie (%)
[25] [26]	20222025	TSeption	$83,15 \pm 0,36$
[27] [26]	20222025	ConvNext	$81,95 \pm 0,61$
[28] [26]	20232025	LMDA	$81,06 \pm 0,99$
[26]	2025	NLMda-Net	$83,71 \pm 0,30$
[29]	2023	EDJAN Transfer de învățare	0.76
[30]	2023	CNN+LSTM	$85,1 \pm 0,5$
[30]	2023	ATT+CNN+LSTM	$85,6 \pm 0,3$
[30]	2023	Fantomă+LSTM	$86,6 \pm 0,4$
[30]	2023	ATT+Fantomă+LSTM	$87,3 \pm 0,2$
[30]	2023	CNN+LST	$85,1 \pm 0,5$
		Model propus FNCA+DNN 12 subiecte	$0,9429 \pm 0,0028$
		Model propus FNCA+DNN 21 Subiecte	$0,9083\% \pm 0,0012$

## 4.4 Concluziile capitolului

Modelul propus FNCA + DNN abordează limitările cheie ale abordărilor anterioare prin utilizarea FNCA pentru învățarea metrică, creând un spațiu de caracteristici mai discriminativ care îmbunătățește separabilitatea claselor înainte de clasificarea DNN. Întreruperea și normalizarea lotului reduc supraajustarea, în timp ce

un mecanism de atenție integrat permite modelului să prioritizeze dinamic canalele EEG relevante și benzile de frecvență. Evaluat pe setul de date SEED-VIG, modelul atinge o acuratețe de ultimă generație - 94,29% cu 12 subiecți și 90,389% cu 21 de subiecți - depășind metode precum TSception, ConvNeXt, LMDA-Net și CNN+LSTM. Aceste rezultate demonstrează eficacitatea modelului și aplicabilitatea în timp real pentru integrarea în mașini inteligente și sisteme portabile. Lucrările viitoare se vor concentra pe îmbunătățirea generalizării între subiecte, extinderea seturilor de date cu date de conducere din lumea reală, explorarea implementărilor hardware încorporate și testarea tehnicilor avansate de modelare a secvențelor precum Mamba și xLSTM pentru a capta mai bine modelele de semnal EEG în timp.




# **Capitolul 5 EFFRES- DROWSYNET: UN NOU MODEL HIBRID CARE UTILIZEAZĂ EFFICIENTNET-B0 ȘI RESNET-50 PENTRU DETECTAREA SOMNOLENȚEI ȘOFERULUI**

Modelul hibrid propus integrează EfficientNetB0 și ResNet50. EfficientNetB0 oferă o arhitectură scalabilă pentru intrări vizuale variate, în timp ce ResNet50 surprinde caracteristici subtile prin conexiuni reziduale. [31][32]

Acest capitol oferă o analiză detaliată a modelului hibrid propus pentru detectarea oboselii șoferului, evaluează performanța acestuia pe un set de date video adnotat în diverse condiții demografice și de iluminare și îl compară cu metodele recente de ultimă generație.

## **5.1 Preprocesarea datelor, extragerea caracteristicilor și implementarea modelului hibrid**

Pentru a detecta somnolența șoferului, indiciile faciale, cum ar fi închiderea ochilor și căscatul, au fost analizate folosind cadre video din seturile de date SUST-DDD și YawDD. Detectorul facial bazat pe HOG de la Dlib și modelul de reper facial în 68 de puncte au fost utilizate pentru identificarea robustă a trăsăturilor faciale cheie sub diferite iluminări și orientări. Aceste repere au permis calcularea raportului de aspect al ochilor (EAR) și al raportului de aspect al gurii (MAR), care au servit ca indicatori primari ai oboselii. Pozițiile și ordinea celor 68 de repere faciale utilizate pentru calculul EAR și MAR sunt ilustrate în Cifra 5.1.




**Cifră 5.1** Identificarea reperelor faciale folosind Dlib. a. Repere faciale. b. Poziția și ordinea de 68 de puncte pe față

Valorile EAR sub un prag dinamic, specific video au indicat închiderea ochilor, în timp ce valorile MAR peste un prag adaptiv similar au semnalat căscat. Fiecare cadru a fost supus unei conduite de preprocesare: detectarea și decuparea feței, redimensionarea la  $224 \times 224$  pixeli, conversia tonurilor de gri, normalizarea iluminării folosind CLAHE și scalarea pixelilor la  $[0,1]$ . [33, 34]

Cadrele cu EAR scăzut și MAR ridicat au fost etichetate ca somnoroase (Cifră 5.2), în timp ce cei cu EAR ridicat și MAR scăzut au indicat vigilență (Cifră 5.3). Aceste cadre etichetate au format intrarea pentru modelul de clasificare.



**Cifră 5.2** Eșantioane de cadre de ieșire de somnolență extrase din setul de date video.



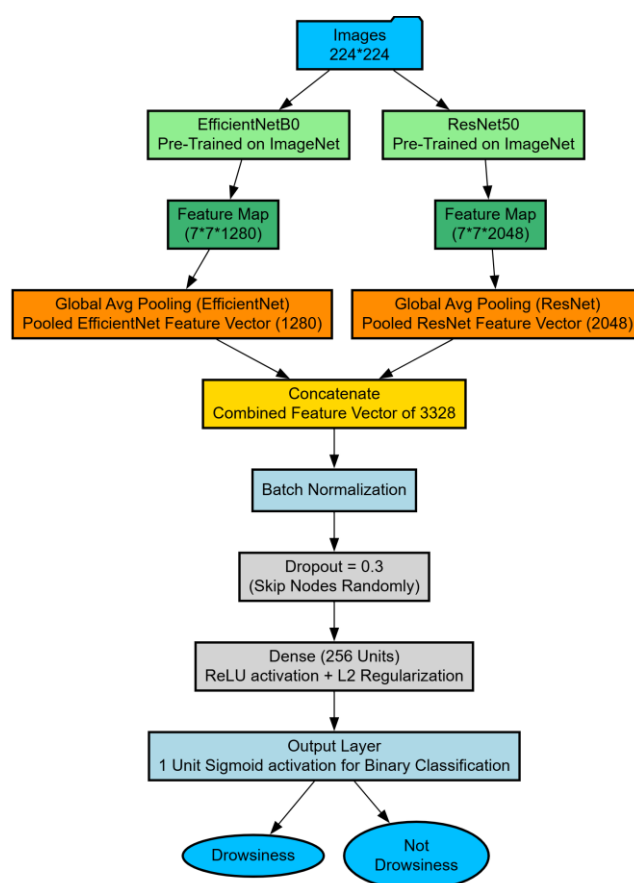
**Cifră 5.3** Eșantioane de cadre de ieșire fără somnolență extrase din setul de date video.

Un model hibrid de învățare profundă a fost dezvoltat prin integrarea arhitecturilor EfficientNetB0 și ResNet50 pentru a valorifica capacitățile lor complementare de extragere a caracteristicilor. Caracteristicile din ambele coloane vertebrale au fost extrase, grupate și concatenate, urmate de normalizarea lotului, un strat de abandon (rata 0,3) și un strat dens cu regularizare L2. Stratul de ieșire a folosit o activare sigmoidă pentru clasificarea binară (Cifră 5.4). Modelul a fost compilat cu optimizatorul Adam și pierdere de entropie încrucișată binară și evaluat folosind acuratețea, precizia și reamintirea. Instruirea a folosit apeluri inverse, inclusiv EarlyStopping, ReduceLROnPlateau, ModelCheckpoint și TensorBoard. Augmentarea

datelor a fost aplicată folosind ImageDataGenerator și a fost implementată o strategie de reglare fină în două faze folosind TensorFlow și Keras.

## Rezultate și discuții

Un nou model hibrid de învățare profundă a fost dezvoltat prin integrarea a două arhitecturi proeminente de rețele neuronale convoluționale, EfficientNetB0 și ResNet50. Motivația principală din spatele acestei abordări a fost de a valorifica caracteristicile și punctele forte distincte ale ambelor arhitecturi pentru a îmbunătăți capacitatea modelului de a generaliza și clasifica cu precizie imaginile într-un cadru de clasificare binară. Combinația acestor modele a avut ca scop captarea unui spectru larg de caracteristici, variind de la modele de bază la modele complexe, îmbunătățind astfel performanța predictivă a modelului pe seturi de date complexe.



*Cifra 5.4 Arhitectura de rețele hibridă EffecianetB0+ResNet50.*

## 5.2 Evaluarea performanței EFFRES-DrowsyNet în diferite epoci de antrenament pe setul de date SUST-DDD


Această secțiune analizează performanța modelului pe setul de date SUST-DDD în diferite epoci de antrenament, cu și fără oprire timpurie. Valorile cheie de evaluare

includ acuratețea testului, precizia, reamintirea și pierderea. Obiectivul este de a evalua modul în care durata antrenamentului afectează eficacitatea modelului și de a identifica configurația optimă. [16]Masă 5.1 rezumă performanța în diferite configurații experimentale, evidențiind influența epocilor de antrenament și a criteriilor de oprire asupra rezultatelor generale.

**Masă 5.1** Indicatori de performanță în diferite epoci de antrenament pentru execuții experimentale distincte.

Numărul experimentului	Epoci	Precizia testului	Precizie de testare	Rechamar ea testului	Pierderea testelor
1	10	93.67%	96.87%	90.25%	21.03%
2	20	95.42%	96.66%	94.08%	13.22%
3	30	96.96%	97.47%	96.52%	8.47%
4	40 Opreire devreme la Epoca 25	97.71%	98.07%	97.33%	8.81%
5	50	97.29%	96.40%	98.25%	8.76%
6	60	97.29%	97.25%	97.33%	08.50%
7	70 Opreire devreme la Epoca 36	97.46%	97.03%	97.92%	8.38%
8	80 Opreire devreme la Epoca 32	97.33%	98.22%	96.42%	9.01%
9	90	95.92%	94.87%	97.08%	12.55%
10	100 Opreire devreme la Epoch 22	96.83%	95.69%	98.08%	13.47%

Cifra 5.5 Evaluarea performanței unui nou model hibrid de-a lungul epocilor de antrenament. delimitează impactul diferitelor epoci de antrenament asupra acurateței, preciziei, reamintirii și pierderii indicatorilor cheie de performanță în zece configurații experimentale distincte.



**Cifra 5.5** Evaluarea performanței unui nou model hibrid de-a lungul epocilor de antrenament.

Această diagramă cu bare arată performanța modelului în zece experimente cu 10-100 de epoci de antrenament, folosind acuratețea testului, precizia, reamintirea (axa y primară) și pierderea (axa y secundară). Unele curse au folosit oprirea devreme pentru a preveni supraajustarea. Barele adnotate evidențiază modul în care durata antrenamentului afectează performanța, ajutând la identificarea strategiilor optime de antrenament.

### 5.2.1 Analiza performanței antrenamentului modelului (cu 40 de epoci și oprire timpurie la epoca 25) pe setul de date SUST-DDD

Această secțiune analizează performanța modelului în timpul fazei de antrenament inițial (epocile 1-25), concentrându-se pe dinamica învățării timpurii și optimizare. Instruirea a început cu o pierdere de 4,5076, atingând o acuratețe de 75,66%, o precizie de 74,68% și o reamintire de 77,63% până la sfârșitul primei epoci, cu o acuratețe de validare de 89,25%. Acuratețea validării a atins un vârf de 93,12% până în epoca a 6-a. Rata de învățare a fost redusă de la 0,0001 la 0,00001 după epoca 20 pentru a spori convergența. Instruirea s-a încheiat la epoca 25 din cauza lipsei de îmbunătățiri dincolo de pragul de validare de 93,54%. Acuratețea, precizia și rechemarea stabilizate, indicând performanțe optimizate. Rezultatele finale ale testelor au arătat o acuratețe de 97,71%, o precizie de 98,07%, o rechemare de 97,33% și o pierdere de 8,81%.

### 5.2.2 Compararea modelului de învățare profundă hibrid propus cu modelele existente.

Pentru a evalua eficacitatea modelului hibrid propus în detectarea somnolenței șoferului, a fost efectuată o analiză comparativă cu mai multe modele consacrate, VGG19 + LSTM, VGG16 + LSTM, AlexNet + LSTM și VGGFaceNet + LSTM, aplicate inițial setului de date prezentat în . Performanța fiecărui model a fost evaluată pe baza acurateței, preciziei și reamintirii, valori esențiale pentru măsurarea fiabilității în aplicațiile critice pentru siguranță. După cum se arată în [16]Masă 5.2, modelul hibrid propus depășește în mod constant modelele anterioare la acești indicatori, demonstrând adecvarea sa pentru aplicații în timp real în sistemele de monitorizare a șoferilor.

*Masă 5.2 Analiza comparativă a modelelor de detectare a somnolenței șoferului.*


Model	Precizie (%)	Precizie (%)	Rechemare (%)	Analiză și comparație cu modelul hibrid propus
VGG19 + LSTM [16]	90.53	91.74	91.28	Modelul propus obține scoruri mai mari la toate valorile.
VGG16 + LSTM[16]	89.39	91.81	89.09	Precizie puternică, dar acuratețe și reamintire mai mici; modelul propus depășește performanțele din toate punctele de vedere.
AlexNet + LSTM[16]	63.91	63.78	97.91	Retragere ridicată, dar acuratețe și precizie slabe; Modelul propus oferă performanțe mai echilibrate.
VGGFaceNet + LSTM[16]	84.94	83.65	94.92	Reamintire bună, precizie moderată, precizie scăzută; Modelul propus este superior în toate valorile.
EffRes-DrowsyNet	97.71	98.07	97.33	Cea mai bună performanță generală; combină EfficientNetB0 și ResNet50 pentru o detectare fiabilă, în timp real.

## 5.3 Evaluarea performanței EFFRES-DrowsyNet în diferite epoci de antrenament pe setul de date YawDD

secțiunea sa evaluează modelul EFFRES-DrowsyNet folosind zece experimente (EX1-EX10) pe setul de date YawDD, cu epoci de antrenament variind de la 10 la 100. Obiectivul a fost de a evalua efectul duratei antrenamentului asupra acurateței, preciziei, rechemării și pierderii testului. După cum se arată în [17] Masă 5.3 și Cifra 5.6, performanța modelului s-a îmbunătățit constant în EX1–EX4. EX5-EX7, folosind oprirea timpurie, a menținut performanțe ridicate și a evitat supraajustarea, EX7 (oprit la 38 de epoci) obținând cel mai bun echilibru general. În schimb, EX8-EX10 a arătat o stagnare sau o scădere a performanței, indicând un beneficiu limitat al antrenamentului prelungit și un risc mai mare de supraajustare.

*Masă 5.3 Valori de performanță în diferite epoci de antrenament pentru EFFRES-DrowsyNet pe setul de date YawDD.*

Numărul experimentului	Epoci	Pierdere testelor	Precizia testului	Precizie de testare	Rechemarea testului
EX1	10	1.2149	0.8875	0.9564	0.746
EX2	20	0.3699	0.9039	0.8632	0.896
EX3	30	0.3614	0.925	0.9372	0.866
EX4	40	0.452	0.9039	0.9217	0.824
EX5	50 (Oprire devreme la 42)	0.4043	0.8906	0.8863	0.826
EX6	60 (Oprire devreme la 31)	0.4166	0.9102	0.8986	0.868
EX7	70 (Oprire devreme la 38)	0.2905	0.9273	0.9302	0.88
EX8	80 (Oprire timpurie la 42)	0.3696	0.907	0.9045	0.852
EX9	90 (Oprire devreme la 38)	0.2543	0.9094	0.9174	0.844
EX10	100 (Oprire devreme la 37)	0.3671	0.893	0.906	0.81



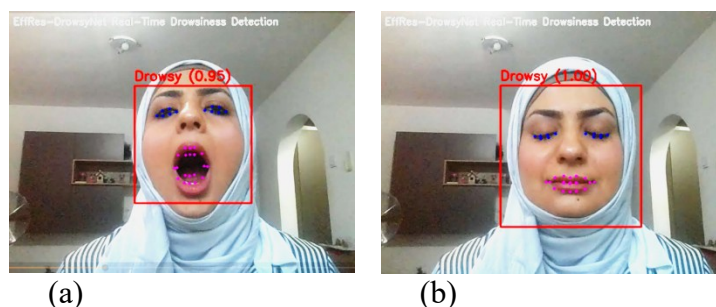
*Cifra 5.6 Valori de performanță în diferite epoci de antrenament pentru EFFRES-DrowsyNet pe setul de date YawDD.*

### 5.3.1 Analiza performanței antrenamentului modelului (cu 70 de epoci și oprire timpurie la Epoca 38) pe setul de date YawDD

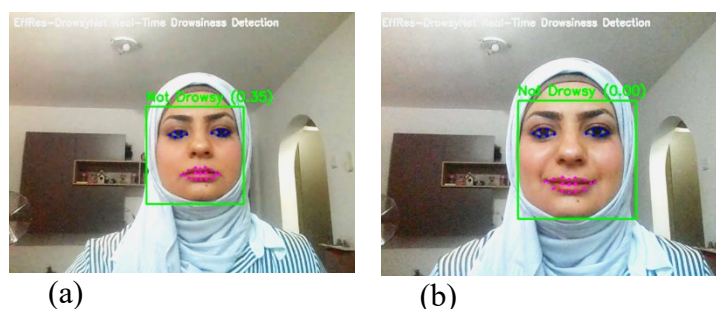
EffRes-DrowsyNet antrenat cu oprire timpurie (EX7) s-a oprit la epoca 38 și a obținut performanțe optime. Epocile timpurii au arătat o îmbunătățire rapidă, acuratețea validării atingând un vârf de 94,92% între epocile 18-28, în timp ce acuratețea antrenamentului a ajuns la 97,38%. În ciuda unei reduceri a ratei de învățare la epoca 33, acuratețea validării s-a stabilizat. Pierderile finale au fost de 0,0884 (antrenament), 0,2704 (validare) și 0,2905 (test). Rezultatele testelor au confirmat robustețea cu o precizie de 92,73%, o precizie de 93,02% și o reamintire de 88,00%.

## 5.4 Detectarea somnolenței în timp real folosind EffRes-DrowsyNet

Pentru a valida utilizarea practică a modelului propus EffRes-DrowsyNet, a fost dezvoltat un sistem în timp real folosind o cameră web standard pentru laptop. Construit în Python cu OpenCV, Dlib și TensorFlow, captează videoclipuri live, detectează fețele prin reperele de 68 de puncte ale Dlib și preprocesează cadrele pentru a se potrivi cu formatul de intrare al modelului. Modelul antrenat (.h5) prezice somnolența pe cadru folosind un prag de 0,5. Rezultatele sunt afișate cu casete cu coduri de culori și contururi faciale. Rulând pe un laptop Intel Core i7 (16 GB RAM), sistemul atinge 10-15 FPS cu latență scăzută. **Cifra 5.7** și **Cifra 5.8** Arată detectarea cu succes în timp real a stărilor de somnolență și alertă.



**Cifra 5.7** Captură de ecran din sistemul de detectare în timp real care arată o stare de somnolență. Caseta de delimitare este roșie, iar ochii și gura sunt conturate cu markere punctate albastru și, respectiv, roz.



**Cifra 5.8** Captură de ecran din sistemul de detectare în timp real care arată o stare de non-somnolență. Caseta de delimitare este verde, iar trăsăturile feței sunt urmărite în mod constant.

În timp ce prototipul funcționează bine în majoritatea scenariilor, fiabilitatea sa poate fi afectată de variațiile de iluminare ambientală, ocluziile faciale și mișcările extreme ale capului. Aceste provocări evidențiază domenii de îmbunătățire viitoare, cum ar fi încorporarea caracteristicilor temporale prin intermediul rețelelor neuronale recurente sau optimizarea implementării pe platforme încorporate cu acceleratoare de inferență.

În concluzie, implementarea în timp real a EffRes-DrowsyNet confirmă soliditatea sa teoretică, validitatea experimentală și aplicabilitatea practică. Această capacitate în timp real îi întărește potențialul ca instrument eficient pentru detectarea somnolenței în sistemele inteligente de transport și siguranță a șoferilor.

## **5.5 Concluziile capitolului**

Acest capitol a validat modelul hibrid EffRes-DrowsyNet, combinând EfficientNetB0 și ResNet50 pentru detectarea precisă a somnolenței șoferului. Antrenat în condiții variate, modelul a atins o precizie de 97,71%, o precizie de 98,07% și o reamintire de 97,33%, confirmând fiabilitatea sa în lumea reală. Tehnicile de optimizare, cum ar fi oprirea timpurie și ratele de învățare adaptivă, au îmbunătățit performanța, experimentul 4 oferind cel mai bun echilibru metric. Depășind modelele existente, EffRes-DrowsyNet a redus la minimum rezultatele fals pozitive, cruciale pentru monitorizarea în timp real. Lucrările viitoare se vor concentra pe captarea comportamentelor mai nuanțate și pe integrarea datelor senzoriale și în timp real suplimentare pentru o reacție îmbunătățită.



# Capitolul 6 Concluzii și lucrări viitoare

## 6.1 Rezultatele cercetării și contribuțiile

Capitolul 2 a oferit baza teoretică și contextuală pentru cercetare prin furnizarea unei revizuii sistematice a literaturii de specialitate a metodelor actuale de detectare a somnolenței. Această revizuire a clasificat tehnicile pe baza semnalelor fiziologice (EEG, EOG), caracteristicilor vizuale (închiderea ochilor, căscat), rețelelor corporale purtabile (WBAN) și abordărilor hibride. Analiza a dezvăluit lacune semnificative în stadiul actual al tehnologiei, inclusiv definiții inconsistente ale oboselii și somnolenței, sisteme insuficiente în timp real și generalizare slabă între subiecte. Aceste lacune au justificat necesitatea unui cadru de detectare robust, scalabil și multimodal, care să ghideze obiectivele de cercetare și metodologia experimentală.

### Contribuția principală:

- Revizuirea sistematică a literaturii de specialitate a metodelor de detectare a somnolenței:

A fost efectuată o revizuire sistematică a literaturii de specialitate pentru a clasifica și evalua tehnicile existente de detectare a somnolenței, evidențiind punctele forte și limitările acestora.

### Rezultatele au fost publicate ca:

- **Journal:** S.H. Al-Gburi, K.A. Al-Sammak, I. Marghescu, C.C. Oprea, *State of the Art in Drivers' Attention Monitoring – A Systematic Literature Review*, **Karbala International Journal of Modern Science**, 9(1), 2, 10 January 2023, DOI: <https://doi.org/10.33640/2405-609X.3278> [3].

Pentru această lucrare au fost stabilite patru întrebări de cercetare, prin prisma cărora aș dori să rezum pe scurt rezultatele și contribuțiile obținute.

***RQ1: Cum pot fi analizate și preprocesate în mod sistematic seturile de date EEG și video pentru a evalua performanța diferitelor modele de învățare automată și învățare profundă în detectarea somnolenței șoferului?***

Această întrebare de cercetare este abordată în capitolul 3 printr-o analiză sistematică a modalităților EEG și video folosind tehnici tradiționale de învățare automată și învățare profundă. Setul de date EEG TRYOUT a fost utilizat pentru a extrage puterile de bandă alfa și beta, indicatorii cheie ai somnolenței, prin segmentare și analiza spectrală a lui Welch, permițând clasificarea robustă în scheme binare și multiclase. În paralel, setul de date video SUST-DDD a fost procesat folosind Dlib

pentru a calcula rapoartele de aspect ale ochilor și gurii (EAR și MAR), capturând semne vizuale de oboseală pentru clasificarea bazată pe CNN.

Evaluările comparative au arătat performanțe ridicate, Random Forest obținând o acuratețe de 99,99% pe datele EEG și CNN ajungând la 87,58% pe datele video. Provocări precum dezechilibrul clasei și supraajustarea au fost atenuate prin preprocesare personalizată, echilibrare a claselor și strategii de optimizare. Această evaluare duală pune bazele modelelor hibride dezvoltate în capitolele ulterioare.

### **Contribuția principală:**

- Evaluarea comparativă a modelelor:

O evaluare comparativă sistematică a modelelor tradiționale de învățare automată și de învățare profundă a fost efectuată folosind atât seturi de date EEG, cât și video pentru a stabili nivelurile de performanță de bază și pentru a descoperi limitările abordărilor actuale de detectare a somnolenței șoferului. Rezultatele evaluării demonstrează o acuratețe ridicată cu Random Forest pe EEG și performanțe puternice CNN pe datele video.

- Impactul individual investigat al EfficientNet-B0 și ResNet-50:

Am investigat impactul individual al arhitecturilor EfficientNet-B0 și ResNet-50 asupra detectării somnolenței driverului. Evaluând fiecare model în mod independent, am evaluat eficacitatea lor în învățarea caracteristicilor vizuale discriminative. Înțelegerea acestor roluri complementare clarifică de ce combinarea ambelor coloane vertebrale produce cea mai bună precizie generală.

### **Rezultatele au fost publicate ca:**

- **S.H. Al-Gburi, K.A. Al-Sammak, K.M.A. Alheeti, G. Suci, A.G. Abdulqader, *Driver Behaviour Assessment with Different ML Models Using EEG and Physiological Data – A Comparative Study*, in **Proceedings of the 2024 16th International Conference on Electronics, Computers and Artificial Intelligence (ECAI)**, Iași, Romania, 27–28 June 2024, pp. 1–6, IEEE, DOI: 10.1109/ECAI61503.2024.10607554 [19].**
- **S.H. Al-Gburi, K.A. Al-Sammak, N.A.A. Almosa, G. Suci, N.A.H. Al-Sammak, *Comparative Analysis of Logistic Regression and SVM Models for Drowsiness Detection in Drivers*, in **Proceedings of the International Conference on Intelligent and Fuzzy Systems (INFUS 2025)**, Istanbul, Turkey, 29–31 July 2025 [35].**

***RQ2: Cum pot fi optimizate caracteristicile bazate pe EEG folosind analiza rapidă a componentelor de vecinătate și învățarea profundă pentru a îmbunătăți acuratețea și eficiența detectării somnolenței șoferului?***

Această întrebare de cercetare este explorată în capitolul 4, unde teza introduce FNCA-DNN, un cadru nou care combină analiza rapidă a componentelor de vecinătate (FNCA) cu o rețea neuronală profundă (DNN) pentru a îmbunătăți clasificarea somnolenței șoferului bazată pe EEG. FNCA este aplicat ca o tehnică de transformare a caracteristicilor supravegheate, îmbunătățind separabilitatea claselor, păstrând în același timp integritatea dimensională a datelor. Acest lucru are ca rezultat reprezentări

mai discriminative și mai interpretabile ale caracteristicilor, ceea ce duce la îmbunătățirea eficienței antrenamentului și a acurateții clasificării.

Modelul a fost antrenat și validat pe setul de date SEED-VIG, obținând o acuratețe de 94,29% folosind date de la 12 subiecți și o acuratețe de 90,83% folosind date de la 21 de subiecți. FNCA-DNN a fost comparat cu mai multe modele de ultimă generație, inclusiv TSception, ConvNeXt LMDA-Net și CNN+LSTM, și le-a depășit în mod constant atât în scenariile de evaluare specifice subiectului, cât și în cele inter-subiecte.

În plus, modelul a demonstrat capacități puternice de generalizare între indivizi, confirmând robustețea și adecvarea sa pentru aplicațiile de detectare a somnolenței.

#### **Principalele contribuții:**

- Analiza performanței modelelor bazate pe EEG pentru detectarea comportamentului șoferului:

A fost efectuată o evaluare cuprinzătoare a mai multor modele de învățare automată și învățare profundă pentru a evalua eficacitatea acestora în clasificarea stărilor de conducere pe baza semnalelor EEG. Această analiză a identificat caracteristici spectrale cheie care contribuie la detectarea fiabilă a somnolenței și vigilenței, oferind informații despre relevanța caracteristicilor și comportamentul modelului. Constatările au fost revizuite și publicate în .[36]

- Dezvoltarea modelului FNCA-DNN:

A fost propus un nou cadru Fast Neighborhood Component Analysis-Deep Neural Network (FNCA-DNN), care combină transformarea supravegheată a caracteristicilor cu învățarea profundă pentru o clasificare optimizată bazată pe EEG. Modelul îmbunătățește semnificativ atât acuratețea, cât și interpretabilitatea în sarcinile de detectare a somnolenței șoferului. Arhitectura, implementarea și validarea experimentală sunt detaliate în .[37]

#### **Rezultatele au fost publicate ca:**

- **S.H. Al-Gburi, K.A. Al-Sammak, I. Marghescu, C.C. Oprea, K.M.A. Alheeti, N.A.A. Almosa, *Analyzing Different Models for Driver Behaviour Detection Using EEG Data*, in **Proceedings of the 2024 15th International Conference on Communications (COMM)**, Bucharest, Romania, 03–04 October 2024, pp. 1–5, IEEE, DOI: 10.1109/COMM62355.2024.10741402 [36].**
- **S.H. Al-Gburi, K.A. Al-Sammak, I. Marghescu, C.C. Oprea, A.-M.C. Drăgulescu, G. Suci, K.M.A. Alheeti, N.A.M. Alduais, N.A.H. Al-Sammak, *Introducing a Novel Fast Neighbourhood Component Analysis–Deep Neural Network Model for Enhanced Driver Drowsiness Detection in Big Data and Cognitive Computing*, **9(5)**, 126, 08 May 2025, DOI: 10.3390/bdcc9050126, ISI Q1 (2025), WOS: 001497786100001 [37].**

***RQ3: Cum poate o arhitectură hibridă de învățare profundă bazată pe procesarea imaginilor să îmbunătățească detectarea în timp real a somnolenței șoferului în condiții reale?***

Această întrebare este abordată în capitolul 5 prin introducerea EFFRES-DrowsyNet, un model hibrid de învățare profundă care combină EfficientNetB0 și ResNet50 pentru extragerea trăsăturilor faciale și detectarea somnolenței. Modelul captează indicii vizuale subtile, cum ar fi clipirea și căscatul folosind cadre video

preprocesate îmbunătățite de CLAHE și normalizarea tonurilor de gri, cu EAR și MAR ca caracteristici cheie de intrare.

Evaluat pe seturi de date din lumea reală, modelul a atins o acuratețe de 97,71%, o precizie de 98,07% și o reamintire de 97,33%. A demonstrat o robustețe puternică la lumină și variații de poziție a capului și a depășit CNN-urile convenționale. Designul său ușor și scalabil acceptă implementarea în timp real în sistemele de monitorizare a driverelor încorporate.

#### **Contribuție principală:**

- Proiectarea modelului EFFRES-DrowsyNet:

O nouă arhitectură hibridă de învățare profundă, EFFRES-DrowsyNet, a fost dezvoltată prin integrarea EfficientNetB0 și ResNet50 pentru a permite extragerea robustă și precisă a trăsăturilor faciale din datele video. Modelul a demonstrat o precizie ridicată de detecție și rezistență la variațiile de iluminare și de poziție a capului, făcându-l potrivit pentru aplicațiile reale de detectare a somnolenței.

#### **Rezultatele au fost publicate ca:**

- **S.H. Al-Gburi, K.A. Al-Sammak, I. Marghescu, C.C. Oprea, A.-M.C. Drăgulescu, N.A.M. Alduais, K.M.A. Alheeti, N.A.H. Al-Sammak, N.A.H.** *EffRes-DrowsyNet: A Novel Hybrid Deep Learning Model Combining EfficientNetB0 and ResNet50 for Driver Drowsiness Detection* in **Sensors**, **25**, **3711**, 13 June 2025, DOI:10.3390/s25123711, **ISI Q2 (2025), WOS: [38]**.

***RQ4: Cum se compară modelele propuse cu metodele de ultimă generație existente în ceea ce privește valorile de performanță și robustețea seturilor de date de referință?***

Această întrebare de cercetare este abordată în capitolele 4 și 5 prin analize comparative ale modelelor propuse FNCA-DNN și EFFRES-DrowsyNet cu metodele tradiționale de învățare automată și de învățare profundă modernă pe mai multe seturi de date de referință.

FNCA-DNN a depășit modele precum Random Forest, Gradient Boosting, TSception și CNN+LSTM pe setul de date SEED-VIG, obținând o acuratețe de 94,29% (12 subiecți) și 90,83% (21 de subiecți), demonstrând o generalizare puternică între scenarii specifice subiectului și între subiecți.

EFFRES-DrowsyNet a arătat performanțe superioare pe seturile de date SUST-DDD și YawDD, cu o acuratețe de 97,71%, o precizie de 98,07% și o reamintire de 97,33%. De asemenea, a menținut convergența stabilă și robustețea în condiții de variații de iluminare și poziție a capului.

Aceste rezultate confirmă fiabilitatea, scalabilitatea și aplicabilitatea în timp real a ambelor modele pentru sistemele practice de monitorizare a șoferilor.

#### **Contribuție principală:**

- Validarea experimentală și superioritatea modelelor propuse:

Prin experimente comparative extinse, FNCA-DNN și EFFRES-DrowsyNet propuse au depășit în mod constant abordările convenționale de învățare automată și de învățare profundă în mai multe seturi de date de referință și condiții de testare. Performanța lor puternică în acuratețe, robustețe și generalizare confirmă viabilitatea lor pentru implementarea în timp real în sistemele de monitorizare a șoferilor.[37, 38]

Împreună, aceste contribuții reprezintă un progres semnificativ în domeniul detectării somnolenței șoferului prin introducerea unui cadru multimodal, de înaltă performanță și scalabil, capabil să susțină tehnologii inteligente, adaptabile și în timp real de asistență a șoferului.

#### **Rezultatele au fost publicate ca:**

- **S.H. Al-Gburi**, K.A. Al-Sammak, I. Marghescu, C.C. Oprea, A.-M.C. Drăgulescu, G. Suci, K.M.A. Alheeti, N.A.M. Alduais, N.A.H. Al-Sammak, *Introducing a Novel Fast Neighbourhood Component Analysis–Deep Neural Network Model for Enhanced Driver Drowsiness Detection* in **Big Data and Cognitive Computing**, **9(5)**, 126, 08 May 2025, DOI: 10.3390/bdcc9050126, **ISI Q1 (2025)**, **WOS: 001497786100001** [37].
- **S.H. Al-Gburi**, K.A. Al-Sammak, I. Marghescu, C.C. Oprea, A.-M.C. Drăgulescu, N.A.M. Alduais, K.M.A. Alheeti, N.A.H. Al-Sammak, N.A.H. *EffRes-DrowsyNet: A Novel Hybrid Deep Learning Model Combining EfficientNetB0 and ResNet50 for Driver Drowsiness Detection* in **Sensors**, **25**, 3711, 13 June 2025, DOI:10.3390/s25123711, **ISI Q2 (2025)**, **WOS: [38]**.

Această teză prezintă un cadru scalabil, de înaltă performanță pentru detectarea somnolenței șoferului folosind EEG și date vizuale. Introduce două modele: FNCA-DNN, care combină selecția caracteristicilor cu învățarea profundă pentru analiza EEG și EFFRES-DrowsyNet, un CNN hibrid care utilizează EfficientNetB0 și ResNet50 pentru detectarea vizuală. Ambele modele depășesc metodele tradiționale și sunt validate pentru implementare în timp real, abordând limitările cheie ale sistemelor existente de monitorizare a șoferilor prin soluții multimodale, robuste și eficiente.

## **6.2 Lista publicațiilor originale**

Cercetarea prezentată în această teză a avut ca rezultat următoarele publicații peer-reviewed:

- [1] **Journal: S.H. Al-Gburi**, K.A. Al-Sammak, I. Marghescu, C.C. Oprea, A.-M.C. Drăgulescu, N.A.M. Alduais, **K Journal: S.H. Al-Gburi**, K.A. Al-Sammak, I. Marghescu, C.C. Oprea, A.-M.C. Drăgulescu, N.A.M. Alduais, K.M.A. Alheeti, N.A.H. Al-Sammak, N.A.H. *EffRes-DrowsyNet: A Novel Hybrid Deep Learning Model Combining EfficientNetB0 and ResNet50 for Driver Drowsiness Detection* in **Sensors**, **25**, 3711, 13 June 2025, DOI:10.3390/s25123711, **ISI Q2 (2025)**, **WOS:001516386400001**
- [2] **Journal: S.H. Al-Gburi**, K.A. Al-Sammak, I. Marghescu, C.C. Oprea, A.-M.C. Drăgulescu, G. Suci, K.M.A. Alheeti, N.A.M. Alduais, N.A.H. Al-Sammak, *Introducing a Novel Fast Neighbourhood Component Analysis–Deep Neural Network Model for Enhanced Driver Drowsiness Detection* in **Big Data and Cognitive Computing**, **9(5)**, 126, 08 May 2025, DOI: 10.3390/bdcc9050126, **ISI Q1 (2025)**, **WOS:001497786100001**.

- [3] **Conference:** S.H. Al-Gburi, K.A. Al-Sammak, I. Marghescu, C.C. Oprea, K.M.A. Alheeti, N.A.A. Almosa, *Analyzing Different Models for Driver Behaviour Detection Using EEG Data*, in **Proceedings of the 2024 15th International Conference on Communications (COMM)**, Bucharest, Romania, 03–04 October 2024, pp. 1–5, **IEEE**, DOI: 10.1109/COMM62355.2024.10741402.
- [4] **Conference:** S.H. Al-Gburi, K.A. Al-Sammak, K.M.A. Alheeti, G. Suciuc, A.G. Abdulqader, *Driver Behaviour Assessment with Different ML Models Using EEG and Physiological Data – A Comparative Study*, in **Proceedings of the 2024 16th International Conference on Electronics, Computers and Artificial Intelligence (ECAI)**, Iași, Romania, 27–28 June 2024, pp. 1–6, **IEEE**, DOI: 10.1109/ECAI61503.2024.10607554.
- [5] **Journal:** S.H. Al-Gburi, K.A. Al-Sammak, I. Marghescu, C.C. Oprea, *State of the Art in Drivers' Attention Monitoring – A Systematic Literature Review*, **Karbala International Journal of Modern Science**, 9(1), 2, 10 January 2023, DOI: <https://doi.org/10.33640/2405-609X.3278>
- [6] **Conference:** S.H. Al-Gburi, K.A. Al-Sammak, N.A.A. Almosa, G. Suciuc, N.A.H. Al-Sammak, *Comparative Analysis of Logistic Regression and SVM Models for Drowsiness Detection in Drivers*, in **Proceedings of the International Conference on Intelligent and Fuzzy Systems (INFUS 2025)**, Istanbul, Turkey, 29–31 July 2025.
- [7] **Journal:** K. A. Al-Sammak, S. H. Al-Gburi, I. Marghescu, A.-M. C. Drăgulinescu, C. Marghescu, A. Martian, N. A. M. Alduais, and N. A. H. Al-Sammak, “*Optimizing LoRaWAN Gateway Placement in Urban Environments: A Hybrid PSO-DE Algorithm Validated via HTZ Simulations*,” **Technologies**, vol. 13, no. 6, p. 256, 17 June 2025, <https://doi.org/10.3390/technologies13060256>, **ISI Q1 (2025)**, **WOS:001514625000001**
- [8] **Journal:** K.A. Al-Sammak, S.H. Al-Gburi, I. Marghescu, A.-M.C. Drăgulinescu, C. Marghescu, A. Martian, N.A.H. Al-Sammak, G. Suciuc, K.M.A. Alheeti, *Optimizing IoT Energy Efficiency: Real-Time Adaptive Algorithms for Smart Meters with LoRaWAN and NB-IoT*, **Energies**, 18(4), 987, 18 February 2025, **ISI Q3**, **WOS:001431808900001**.
- [9] **Conference:** K.A. Al-Sammak, S.H. Al-Gburi, I. Marghescu, A.M. Drăgulinescu, C. Marghescu, N.A.H. Al-Sammak, *An Experimental Study of Power Consumption in Narrowband IoT Devices*, in **Proceedings of the 2024 15th International Conference on Communications (COMM)**, Bucharest, Romania, 03–04 October 2024, pp. 1–6, **IEEE**, DOI: 10.1109/COMM62355.2024.10741514.
- [10] **Conference:** K.A. Al-Sammak, S.H. Al-Gburi, C. Marghescu, A.M. Drăgulinescu, G. Suciuc, A.G. Abdulqader, *A Comprehensive Assessment of LoRaWAN and NB-IoT Performance Metrics Under Varied Payload Data Sizes*, in **Proceedings of the 2024 16th International Conference on Electronics, Computers and Artificial Intelligence (ECAI)**, Iași, Romania, 27–28 June 2024, pp. 1–5, **IEEE**, DOI: 10.1109/ECAI61503.2024.10607481.

- [11] **Conference:** K.A. Al-Sammak, S.H. Al-Gburi, I. Marghescu, *Communications Systems in Smart Metering: A Concise Systematic Literature Review*, in **Proceedings of the 2022 14th International Conference on Communications (COMM)**, Bucharest, Romania, 16–18 June 2022, pp. 1–9, IEEE, DOI: 10.1109/COMM54429.2022.9817154.
- [12] **Conference:** G. Suci, C. Stalidi, K.A. Al-Sammak, S.H. Al-Gburi, M.-A. Sachian, *Integrated Solution Based on Innovative Digital Technologies for Smart Ports*, **FOR-FREIGHT Project White Paper**, BEIA Consult International, Bucharest, Romania, 2023, available at: <https://www.for-freight.eu/publications/>.
- [13] **Conference:** K.A. Al-Sammak, S.H. Al-Gburi, N.A.H. Al-Sammak, G. Suci, *An Evaluation of the Functionality of NB-IoT for Smart Metering Applications*, in **Proceedings of the International Conference on Intelligent and Fuzzy Systems (INFUS 2025)**, Istanbul, Turkey, 29–31 July 2025.

## 6.3 Lucrări viitoare

Mai multe direcții pentru cercetări viitoare pot fi explorate pentru a se baza pe concluziile acestui studiu. Acestea includ:

- **Integrarea cu sistemele avansate de asistență a șoferului (ADAS):** Îmbunătățirea monitorizării în timp real prin încorporarea modelelor propuse în cadrele ADAS pentru o intervenție fără probleme.
- **Fuziunea datelor multimodale:** Combinarea semnalelor fiziologice suplimentare (de exemplu, ritmul cardiac, conductanța pielii) cu EEG și date video pentru a îmbunătăți acuratețea detectării. Lucrările viitoare ar trebui să se concentreze pe integrarea unor tehnici de fuziune multimodală mai robuste.
- **Optimizare pentru implementarea Edge AI:** Dezvoltarea de versiuni ușoare ale modelelor propuse pentru a facilita implementarea pe sisteme încorporate și dispozitive edge. Acest lucru va permite inferența în timp real fără a necesita resurse mari de calcul.
- **Considerații etice și de reglementare:** Abordarea preocupărilor legate de confidențialitatea datelor și asigurarea conformității cu standardele internaționale de siguranță pentru adoptarea pe scară largă. Cercetările viitoare ar trebui să se concentreze asupra provocărilor de reglementare și a implementării etice a IA în monitorizarea conducătorilor auto.

Pe scurt, această cercetare a pus o bază solidă pentru progresele viitoare în tehnologiile de monitorizare a șoferilor. Metodologiile propuse au potențialul de a fi integrate în aplicații din lumea reală, îmbunătățind siguranța șoferului și reducând accidentele rutiere cauzate de oboseală. Studiile viitoare ar trebui să se concentreze pe rafinarea și extinderea acestor tehnici pentru a spori și mai mult eficiența și aplicabilitatea lor în sistemele de transport inteligente.

# Referințe

- [1] S. Arumugam and R. Bhargavi, "A survey on driving behavior analysis in usage based insurance using big data," *J. Big Data*, vol. 6, no. 1, pp. 1–21, 2019.
- [2] A. Fouad, "A robust and efficient EEG-based drowsiness detection system using different machine learning algorithms," *Ain Shams Eng. J.*, vol. 14, no. 3, p. 101895, 2023.
- [3] S. H. Al-Gburi, K. A. Al-Sammak, I. Marghescu, and C. C. Oprea, "State of the art in drivers' attention monitoring – A systematic literature review," *Karbala Int. J. Mod. Sci.*, vol. 9, no. 1, p. 2, 2023.
- [4] S. Yaacob, N. A. I. Affandi, P. Krishnan, A. Rasyadan, M. Yaakop, and F. Mohamed, "Drowsiness detection using EEG and ECG signals," in *Proc. 2020 IEEE 2nd Int. Conf. Artif. Intell. Eng. Technol. (IICAET)*, pp. 1–5, IEEE, 2020.
- [5] The Association for Safe International Road Travel (ASIRT), "Road safety facts," [Online]. Available: <https://www.asirt.org/safe-travel/road-safety-facts/>
- [6] M. Shahverdy, M. Fathy, R. Berangi, and M. Sabokrou, "Driver behavior detection and classification using deep convolutional neural networks," *Expert Syst. Appl.*, vol. 149, p. 113240, 2020.
- [7] N. Peppes, T. Alexakis, E. Adamopoulou, and K. Demestichas, "Driving behaviour analysis using machine and deep learning methods for continuous streams of vehicular data," *Sensors*, vol. 21, no. 14, p. 4704, 2021.
- [8] Z. Zhuxin and X. Zheng, "Challenges of the development of intelligent transportation to the transport law system," in *Proc. Int. Conf. Adv. ICT Educ. (ICAICTE)*, 2013, pp. 617–622.
- [9] T. Arakawa, "Trends and future prospects of the drowsiness detection and estimation technology," *Sensors*, vol. 21, no. 7921, 2021.
- [10] Y. Albadawi, M. Takruri, and M. Awad, "A review of recent developments in driver drowsiness detection systems," *Sensors*, vol. 22, no. 5, p. 2069, 2022.
- [11] A. Korotcov, V. Tkachenko, D. P. Russo, and S. Ekins, "Comparison of deep learning with multiple machine learning methods and metrics using diverse drug discovery data sets," *Mol. Pharmaceutics*, vol. 14, pp. 4462–4475, 2017.
- [12] A. Eichberger and S. Arefnezhad, "Dataset 'TRYOUT' for Drowsiness Detection in Drivers," 2021. [Online]. Available: <https://repository.tugraz.at/records/a4nsk-qyh91>
- [13] J. Min, P. Wang, and J. Hu, "The original EEG data for driver fatigue detection," *figshare*, Jul. 2017. [Online]. Available: <https://doi.org/10.6084/m9.figshare.5202739.v1>
- [14] C. Xiang, X. Fan, D. Bai, K. Lv, and X. Lei, "A resting-state EEG dataset for sleep deprivation," *OpenNeuro*, 2024, [Dataset]. doi: 10.18112/openneuro.ds004902.v1.0.5
- [15] W.-L. Zheng and B.-L. Lu, "A multimodal approach to estimating vigilance using EEG and forehead EOG," *J. Neural Eng.*, vol. 14, no. 2, p. 026017, 2017.
- [16] E. K. Yilmaz and M. A. Akcayol, "SUST-DDD: A real-drive dataset for driver drowsiness detection," in *Proc. Conf. Open Innovations Assoc. (FRUCT)*, vol. 6, 2022.
- [17] S. Abtahi, M. Omidyeganeh, S. Shirmohammadi, and B. Hariri, "YawDD: Yawning Detection Dataset," *IEEE Dataport*, Aug. 1, 2020, doi: 10.21227/e1qm-hb90.
- [18] S. Abtahi, M. Omidyeganeh, S. Shirmohammadi, and B. Hariri, "YawDD: A yawning detection dataset," in *Proc. 5th ACM Multimedia Syst. Conf.*, 2014, pp. 24–28.
- [19] S. H. Al-Gburi, K. A. Al-Sammak, K. M. A. Alheeti, G. Suci, and A. G. Abdulqader, "Driver behavior assessment with different ML models using EEG and physiological data – A comparative study," in *Proc. 16th Int. Conf. Electron., Comput. Artif. Intell. (ECAI)*, Iasi, Romania, 2024.
- [20] I. Stancin, M. Cifrek, and A. Jovic, "A review of EEG signal features and their application in driver drowsiness detection systems," *Sensors*, vol. 21, no. 11, p. 3786, 2021.
- [21] "The Sleep Doctor," 2022. [Online]. Available: <https://thesleepdoctor.com/stages-of-sleep/>
- [22] X. Hua, Y. Ono, L. Peng, and Y. Xu, "Unsupervised learning discriminative MIG detectors in nonhomogeneous clutter," *IEEE Trans. Commun.*, vol. 70, no. 6, pp. 4107–4120, 2022.



- [23] V. J. Lawhern, A. J. Solon, N. R. Waytowich, S. M. Gordon, C. P. Hung, and B. J. Lance, "EEGNet: A compact convolutional neural network for EEG-based brain–computer interfaces," *J. Neural Eng.*, vol. 15, no. 5, p. 056013, 2018.
- [24] R. T. Schirrneister *et al.*, "Deep learning with convolutional neural networks for EEG decoding and visualization," *Hum. Brain Mapp.*, vol. 38, no. 11, pp. 5391–5420, 2017.
- [25] Y. Ding, N. Robinson, S. Zhang, Q. Zeng, and C. Guan, "TSception: Capturing temporal dynamics and spatial asymmetry from EEG for emotion recognition," *IEEE Trans. Affect. Comput.*, vol. 14, pp. 2238–2250, 2023.
- [26] G. Siddhad, S. Dey, P. P. Roy, and M. Iwamura, "Awake at the wheel: Enhancing automotive safety through EEG-based fatigue detection," *arXiv preprint arXiv:2401.12345*, 2024. [Online]. Available: <https://arxiv.org/abs/2401.12345>
- [27] Z. Liu, H. Mao, C.-Y. Wu, C. Feichtenhofer, T. Darrell, and S. Xie, "ConvNet 2020s," in *Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit.*, 2022, pp. 11976–11986.
- [28] Z. Miao, M. Zhao, X. Zhang, and D. Ming, "Lmda-Net: A lightweight multi-dimensional attention network for general EEG-based brain–computer interfaces interpretability," *NeuroImage*, vol. 276, p. 120134, 2023.
- [29] J. Cui, L. Yuan, R. Li, Z. Wang, D. Yang, and T. Jiang, "Benchmarking EEG-based cross-dataset driver drowsiness recognition with deep transfer learning," in *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. (EMBC)*, 2023, pp. 1–6.
- [30] W. Fang, L. Tang, and J. Pan, "AGL-Net: An efficient neural network for EEG-based driver fatigue detection," *J. Integr. Neurosci.*, vol. 22, p. 146, 2023.
- [31] Goswami, G., Vatsa, M., & Singh, R. (2014). RGB-D face recognition with texture and attribute features. *IEEE Transactions on Information Forensics and Security*, 9(10), 1629-1640..
- [32] S. Das, S. Pratihari, B. Pradhan, R. H. Jhaveri, and F. Benedetto, "IoT-assisted automatic driver drowsiness detection through facial movement analysis using deep learning and a U-Net-based architecture," *Information*, vol. 15, no. 1, 2024.
- [33] C. Dewi, R.-C. Chen, C.-W. Chang, S.-H. Wu, X. Jiang, and H. Yu, "Eye aspect ratio for real-time drowsiness detection to improve driver safety," *Electronics*, vol. 11, no. 19, p. 3183, 2022, doi: 10.3390/electronics11193183.
- [34] T. V. N. S. R. S. Mounika, P. H. Phanindra, N. V. V. N. S. C. Reddy, Y. K. K. Reddy, and S. Govindu, "Driver drowsiness detection using eye aspect ratio (EAR), mouth aspect ratio (MAR), and driver distraction using head pose estimation," in *Proc. ICT Soft Comput.*, 2024.
- [35] S. H. Al-Gburi, K. A. Al-Sammak, N. A. A. Almosa, G. Suci, and N. A. H. Al-Sammak, "Comparative analysis of logistic regression and SVM models for drowsiness detection in drivers," in *Proc. Int. Conf. Intell. Fuzzy Syst. (INFUS)*, Istanbul, Turkey, pp. 29–32, Jul. 2025.
- [36] S. H. Al-Gburi, K. A. Al-Sammak, I. Marghescu, C. C. Oprea, K. M. A. Alheeti, and N. A. A. Almosa, "Analyzing different models for driver behavior detection using EEG data," in *Proc. 15th Int. Conf. Commun. (COMM)*, Bucharest, Romania, 2024.
- [37] S. H. Al-Gburi, K. A. Al-Sammak, I. Marghescu, C. C. Oprea, A.-M. C. Drăgulescu, G. Suci, K. M. A. Alheeti, N. A. M. Alduais, and N. A. H. Al-Sammak, "Introducing a novel fast neighbourhood component analysis–deep neural network model for enhanced driver drowsiness detection," *Big Data Cogn. Comput.*, vol. 9, no. 126, 2025.
- [38] S. H. Al-Gburi, K. A. Al-Sammak, I. Marghescu, C. C. Oprea, A.-M. C. Drăgulescu, N. A. M. Alduais, K. M. A. Alheeti, and N. A. H. Al-Sammak, "EffRes-DrowsyNet: A novel hybrid deep learning model combining EfficientNetB0 and ResNet50 for driver drowsiness detection," *Sensors*, vol. 25, p. 3711, 2025.