



Universitatea
Transilvania
din Brașov

ȘCOALA DOCTORALĂ INTERDISCIPLINARĂ

Facultatea de Inginerie Electrică și Știința Calculatoarelor

Obaida ALHOUSRYA

Tehnologiile IoT și IIoT Aplicate în Industria Vehiculelor Electrice

REZUMAT

Conducător științific

Prof. Dr. Petru A. COTFAS

BRAȘOV, 2026

Cuprins

Rezumat.....	3
Capitolul 1 - Introducere	4
1.1 Tema, domeniul și relevanța tezei.....	4
1.2 Scopul, lacunele de cercetare și obiectivele tezei	6
1.3 Structura tezei.....	8
1.4 Metodologia cercetării	10
Capitolul 2: Stadiul actual al cercetării privind IoT/IIoT pentru vehicule electrice.....	13
Capitolul 3 - Arhitectura și implementarea sistemului IoT/IIoT pentru monitorizarea sănătății șoferului	15
Capitolul 4: Optimizare metaeuristică hibridă în condiții de incertitudine	19
Capitolul 5 - Predicția oboselii/sănătății prin AI și evaluarea integrată	23
Capitolul 6: Concluzii și direcții viitoare	28
6.1 Rezultate originale, contribuții și relevanță	28
6.2 Concluzii generale și direcții viitoare.....	30
6.3 Valorificarea rezultatelor cercetării.....	32
Referințe	33

Rezumat

Această teză de doctorat abordează necesitatea de a trata sănătatea șoferului ca o componentă esențială a funcționării vehiculelor electrice (EV) conectate, și nu ca un simplu modul izolat de monitorizare a conducătorului auto. Lucrarea este încadrată în domeniul doctoral Electronică, Telecomunicații și Tehnologii Informaționale și integrează mai multe discipline conexe: Internet of Things (IoT), Industrial Internet of Things (IIoT), vehicule electrice, calcul cloud-edge, inteligență artificială, învățare automată, senzori multimodali, monitorizarea sănătății șoferului, analiza datelor și optimizarea conștientă de incertitudine. Ideea centrală este că un EV nu trebuie înțeles doar ca un vehicul alimentat de baterii, ci și ca o platformă ciber-fizică conectată, în care telemetria vehiculului, informațiile privind starea șoferului, rețelele de comunicații, serviciile cloud și algoritmi de optimizare interacționează în timp real.

Scopul tezei este de a dezvolta și valida un cadru integrat IoT/IIoT capabil să achiziționeze semnale legate de șofer, să le transmită printr-o cale de comunicație structurată, să le proceseze prin servicii cloud-edge, să estimeze riscurile de sănătate și oboseală cu ajutorul modelelor AI și să sprijine luarea deciziilor prin optimizare în condiții de incertitudine. Cercetarea răspunde fragmentării observate în studiile existente, în care detecția oboselii șoferului, conectivitatea EV, arhitectura IoT/IIoT și rutarea EV sau optimizarea resurselor sunt adesea dezvoltate separat. În schimb, teza conectează aceste elemente într-un singur flux de lucru orientat ingineresc, în care sănătatea șoferului este tratată ca un serviciu de prim rang în ecosistemele EV conectate.

Contribuția originală a tezei este dezvoltată pe trei niveluri. În primul rând, aceasta propune o arhitectură IoT/IIoT stratificată care conectează senzistica multimodală, telemetria structurată, comunicația MQTT/HTTP, preprocesarea la nivel edge, ingestia prin Azure IoT Hub, Azure Stream Analytics, stocarea în Cosmos DB, vizualizarea în Power BI și alertarea. În al doilea rând, dezvoltă un algoritm Hybrid Ant Colony Optimization (HACO) pentru optimizarea drumului minim cu ponderi fuzzy mixte pe arce, oferind un nucleu de rutare conștient de incertitudine. În al treilea rând, dezvoltă și evaluează fluxuri AI multimodale pentru predicția oboselii și a sănătății șoferului pe baza caracteristicilor ECG/HRV, a imaginilor privind starea ochilor și a caracteristicilor asociate respirației. Rezultatele demonstrează o monitorizare aproape în timp real, un comportament puternic de convergență al HACO și performanțe predictive ridicate pentru modalitățile ECG/HRV și ochi, clarificând în același timp limitările detecției bazate exclusiv pe respirație.

Capitolul 1 - Introducere

1.1 Tema, domeniul și relevanța tezei

Lucrarea este poziționată la intersecția dintre mobilitatea conectată, detecția integrată, sistemele informaționale cloud-edge, învățarea automată și optimizarea inteligentă. Teza nu tratează IoT/IIoT doar ca un strat de comunicație și nu tratează detecția oboselii doar ca un exercițiu de clasificare. În schimb, utilizează EV-ul conectat ca mediu operațional complet, în care senzoristica, telemetria, calitatea datelor, inferența, vizualizarea, alertarea și suportul decizional trebuie să funcționeze împreună. Această poziționare este importantă deoarece o avertizare privind sănătatea șoferului nu are valoare practică dacă semnalul nu este achiziționat corect, dacă este întârziat în rețea, dacă tabloul de bord nu îl afișează clar sau dacă logica ulterioară de rutare și alocare a resurselor nu poate utiliza semnalul de risc.

Teza răspunde, de asemenea, limitării practice conform căreia multe studii avansate de monitorizare a șoferului rămân în afara constrângerilor ingineresti de implementare. O acuratețe mare a clasificării nu este suficientă, singură, pentru aplicațiile EV conectate. Un model trebuie să fie compatibil cu telemetria cu lățime de bandă redusă, să tolereze comunicațiile intermitente, să sprijine mesaje trasabile și marcate temporal și să poată distinge ferestrele de semnal de calitate scăzută de dovezi relevante de oboseală. Din acest motiv, teza combină evaluarea algoritmică cu evaluarea la nivel de sistem, astfel încât rezultatele propuse să poată fi interpretate nu numai ca rezultate de laborator, ci și ca elemente constructive pentru servicii de vehicule conectate.

Transportul rutier traversează o tranziție majoră determinată de obiectivele de decarbonizare, preocupările privind securitatea energetică, dezvoltarea tehnologiilor bateriilor și digitalizarea tot mai accentuată a mobilității. Vehiculele electrice se află în centrul acestei tranziții, iar rapoartele recente de piață arată o extindere continuă a adoptării globale a EV-urilor și o creștere a ponderii acestora în vânzările de vehicule noi. La nivel ingineresc, EV-urile moderne nu mai sunt produse electromecanice izolate. Acestea integrează sisteme de management al bateriei, electronica de putere, controlul transmisiei, sisteme avansate de asistență a conducătorului auto, telematică, actualizări over-the-air, diagnosticare la distanță și servicii conectate la cloud. Aceste elemente transformă EV-urile în platforme definite prin software și orientate pe date, care generează continuu telemetrie și interacționează cu infrastructura digitală [1].

Tema tezei, „Tehnologiile IoT și IIoT Aplicate în Industria Vehiculelor Electrice”, se integrează direct în domeniul doctoral Electronică, Telecomunicații și Tehnologii Informaționale. Componenta electronică este reflectată prin senzorială și achiziția datelor, componenta de telecomunicații prin telemetria MQTT/HTTP și ingestia în cloud, iar componenta tehnologiilor informaționale prin procesarea fluxurilor, stocare, tablouri de bord, inferență AI și suport decizional. În același timp, cercetarea are un caracter interdisciplinar deoarece combină sisteme de vehicule conectate, cloud computing, senzori integrați, procesarea semnalelor biomedicale, monitorizarea stării umane, inteligența artificială, optimizarea fuzzy și operarea IoT/IIoT orientată spre flote, unde interoperabilitatea, fiabilitatea, managementul ciclului de viață și integrarea cu platforme back-end sunt esențiale [2,3].

Valoarea practică a IoT/IIoT apare atunci când telemetria este transformată în acțiune. Un ecosistem EV conectat necesită achiziția datelor din surse eterogene, transport fiabil prin protocoale de comunicație, procesare la marginea rețelei pentru răspunsuri cu latență redusă și reducerea lățimii de bandă, servicii cloud pentru stocare și analiză și mecanisme decizionale capabile să acționeze pe baza informațiilor achiziționate. De aceea, arhitecturile edge-cloud sunt prezentate tot mai des ca esențiale pentru mobilitate și sisteme ciber-fizice care necesită atât capacitate de răspuns, cât și scalabilitate. Teza adoptă această perspectivă și dezvoltă o arhitectură în care senzorială, comunicația, procesarea în cloud, vizualizarea, inferența și suportul decizional sunt tratate ca părți ale aceleiași conduite.

Monitorizarea sănătății și oboselii șoferului reprezintă nucleul cercetării orientat spre siguranță. Oboseala, somnolența, stresul și degradarea bruscă a stării de sănătate pot reduce timpul de reacție și conștientizarea situațională, mai ales în condiții de conducere lungă, monotonă, nocturnă sau solicitantă cognitiv. Analizele existente arată că detecția fiabilă beneficiază de combinarea mai multor indicatori, deoarece un singur semnal poate fi afectat de zgomot, condiții de mediu, variabilitate individuală sau defectarea senzorului. Prin urmare, monitorizarea sănătății șoferului nu trebuie limitată la un singur algoritm sau la un singur senzor, ci trebuie să se bazeze pe o abordare multimodală care combină dovezi fiziologice, comportamentale și contextuale [2,3].

Relevanța tezei derivă din faptul că funcționarea EV-urilor conectate depinde atât de starea vehiculului, cât și de starea șoferului. Monitorizarea exclusivă a vehiculului poate omite evenimente de oboseală sau sănătate, în timp ce monitorizarea exclusivă a șofer-

ului, fără luarea în considerare a constrângerilor vehiculului și ale traseului, limitează capacitatea de a face recomandări sigure și fezabile. De exemplu, un risc de oboseală detectat poate necesita o alertă, o recomandare de odihnă, o modificare a traseului sau o acțiune de suport decizional care ține cont de trafic, energie, disponibilitatea stațiilor de încărcare și incertitudinea condițiilor de deplasare. Aceasta motivează un cadru IoT/IIoT integrat care sprijină împreună siguranța, monitorizarea, predicția și luarea deciziilor operaționale în medii EV conectate.

1.2 Scopul, lacunele de cercetare și obiectivele tezei

Scopul acestei teze este de a muta monitorizarea sănătății șoferului de la o sarcină izolată de detecție către un serviciu operațional IoT/IIoT pentru vehicule electrice conectate. Prin urmare, cercetarea nu se oprește la clasificarea oboselii; aceasta investighează modul în care informațiile privind starea șoferului pot fi achiziționate, transmise, procesate, vizualizate și conectate la suportul decizional în condiții de incertitudine.

Scopul principal al tezei este de a proiecta și valida un cadru integrat bazat pe IoT/IIoT pentru monitorizarea în timp real a sănătății șoferului în vehicule electrice conectate și de a dezvolta metode inteligente care transformă observațiile multimodale în suport decizional operațional. Cercetarea este ghidată de două obiective principale. Primul obiectiv este la nivel de sistem: proiectarea și validarea experimentală a unui cadru IoT/IIoT cloud-edge pentru monitorizarea sănătății șoferului folosind detecția multimodală, telemetrie structurată, servicii cloud scalabile, tablouri de bord și alerte. Al doilea obiectiv este la nivel metodologic: dezvoltarea unor modele hibride metaeuristice și AI avansate pentru rutare, alocarea resurselor și detecția timpurie a problemelor de sănătate sau oboseală ale șoferului în condiții de incertitudine.

Teza pornește de la patru lacune principale de cercetare. Prima lacună este lipsa arhitecturilor end-to-end în care sănătatea șoferului este tratată ca un serviciu IoT/IIoT de prim rang. Multe soluții de oboseală și somnolență sunt evaluate ca algoritmi locali sau offline, fără luarea explicită în considerare a ingestiei, analiticii de flux, partiționării edge-cloud, latenței, stocării, tablourilor de bord, securității sau integrării cu serviciile EV. În sens invers, cercetarea EV-IIoT pune adesea accent pe conectivitate, încărcare, mentenanță predictivă, managementul flotelor și optimizarea energiei, dar nu tratează monitorizarea sănătății șoferului ca o cerință arhitecturală centrală [1,2].

A doua lacună vizează exploatarea limitată a datelor multimodale și contextuale în condiții realiste de sistem conectat. Detecția multimodală este recunoscută pe scară largă ca fiind benefică, dar multe studii se bazează încă pe seturi de date restrânse, ipoteze unimodale sau evaluare offline. Acestea evaluează rar pierderile de semnal ale senzorilor, latența, limitările de lățime de bandă, ratele de eșantionare eterogene și datele lipsă, deși acești factori afectează puternic implementarea IoT. Teza răspunde prin proiectarea indicatorilor de calitate a datelor, a telemetriei sincronizate, a preprocesării specifice modalităților și a logicii de fuziune conștientă de calitate, pentru a face inferența privind sănătatea șoferului potrivită pentru conducte IoT/IIoT operaționale [2,3].

A treia lacună este că rutarea EV și optimizarea resurselor sunt rareori conștiente de starea șoferului, mai ales în condiții de incertitudine. Multe studii privind rutarea și încărcarea EV iau în considerare timpul de deplasare, consumul de energie, disponibilitatea stațiilor, ferestrele de timp și incertitudinea fuzzy sau stochastică. Totuși, starea șoferului este adesea ignorată sau reprezentată doar indirect, iar puține abordări integrează indicatori de sănătate sau oboseală ca restricții, penalizări sau declanșatori pentru decizii de rutare. Aceasta creează oportunitatea de a conecta predicția stării șoferului cu optimizarea conștientă de incertitudine, astfel încât sistemul să poată răspunde riscului, nu doar să îl detecteze.

A patra lacună este fragmentarea validării. Unele studii demonstrează prototipuri hardware, dar nu oferă flexibilitate algoritmică, în timp ce altele simulează optimizarea sau comportamentul edge-cloud fără a considera sănătatea șoferului. Prin urmare, teza adoptă o validare orientată pe software și simulare, susținută de seturi de date publice, fluxuri de lucru reproductibile, comparații de referință și scenarii operaționale reprezentative. Această abordare permite evaluarea împreună a arhitecturii, algoritmului de optimizare și modelelor AI, nu ca elemente separate.

Pe baza acestor lacune, teza definește cinci obiective specifice. O1 constă în revizuirea și analiza tehnologiilor IoT/IIoT, a metodelor AI, a monitorizării sănătății șoferului și a optimizării în ecosisteme EV conectate. O2 constă în proiectarea unei arhitecturi IoT/IIoT end-to-end pentru monitorizarea în timp real a sănătății șoferului. O3 constă în dezvoltarea unei metode hibride metaeuristice pentru rutare conștientă de incertitudine sau suport decizional privind resursele. O4 constă în dezvoltarea de modele AI pentru detecția și predicția timpurie a sănătății și oboselii șoferului folosind date multimodale. O5 constă în

validarea arhitecturii propuse, a algoritmului de optimizare și a modelelor AI prin experimente reproductibile, benchmarking și studii de caz integrate.

1.3 Structura tezei

Teza este organizată în șase capitole, urmând o logică progresivă de la motivația cercetării și analiza stadiului actual al cunoașterii la arhitectura sistemului, optimizare, predicție bazată pe AI, validare integrată, concluzii și valorificare. Tabelul 1 sintetizează rolul fiecărui capitol și contribuția sa orientată spre rezultate.

Tabelul 1. Structura capitolelor tezei și focalizarea pe rezultate.

Capitol	Conținut principal	Rol orientat spre rezultate în rezumat
Capitolul 1	Introducere, motivație, lacune de cercetare, obiective și domeniu de aplicare	Definește problema și întrebările de cercetare
Capitolul 2	Stadiul actual al cercetării privind IoT/IIoT, sistemele EV, monitorizarea sănătății șoferului și optimizarea	Identifică lacunele științifice și poziționează teza
Capitolul 3	Arhitectura și implementarea IoT/IIoT pentru monitorizarea sănătății șoferului	Prezintă sistemul cloud-edge, logica telemetriei și rezultatele privind latența operațională
Capitolul 4	Optimizare metaeuristică hibridă în condiții de incertitudine	Dezvoltă și evaluează HA-CO pentru drumuri minime fuzzy mixte
Capitolul 5	Predicția oboselii/sănătății prin AI și evaluarea integrată	Raportează rezultatele pentru ECG/HRV, ochi, respirație și fuziune
Capitolul 6	Concluzii, limitări, direcții viitoare și valorificare	Sintetizează contribuțiile și relevanța practică

Capitolul 1 introduce contextul și motivația, definește problema și lacunele de cercetare, formulează obiectivele și întrebările de cercetare, prezintă metodologia și sintetizează contribuțiile tezei. Acesta poziționează monitorizarea sănătății șoferului ca element necesar al funcționării EV conectate, nu ca funcție periferică.

Capitolul 2 prezintă stadiul actual al cercetării privind IoT/IIoT pentru vehicule electrice. Acesta analizează arhitecturi IoT și IIoT, modele de conectivitate, stive de protocoale, calculul edge-cloud, gemeni digitali, securitate cibernetică, managementul ciclului de viață, monitorizarea multimodală a sănătății șoferului, modele de învățare automată și învățare profundă, platforme IoT de monitorizare a șoferului, rutarea EV și optimizarea resurselor, precum și analiza AI pentru fiabilitatea EV și mentenanța predictivă. Capitolul stabilește baza conceptuală și tehnică a tezei, arătând că cercetarea existentă oferă componente utile, dar nu un cadru EV complet, integrat și conștient de sănătatea șoferului.

Capitolul 3 dezvoltă arhitectura IoT/IIoT propusă și implementarea sistemului pentru monitorizarea sănătății șoferului. Acesta descrie rațiunea proiectării, cerințele funcționale, stratul de senzorială și achiziție, protocoalele de comunicație, schemele de mesaje, constrângerile temporale, ingestia în cloud, procesarea fluxurilor, stocarea, vizualizarea, controalele de securitate, alertarea și feedbackul. Capitolul este orientat spre implementare și arată cum datele multimodale ale șoferului pot fi convertite în telemetrie structurată și procesate printr-o conductă cloud-edge bazată pe Azure IoT Hub, Azure Stream Analytics, Cosmos DB, Power BI, MQTT, HTTP și comunicație protejată prin TLS.

Capitolul 4 dezvoltă componenta de optimizare hibridă metaeuristică. Acesta formulează problema drumului minim cu ponderi fuzzy mixte pe arce, prezintă modele fuzzy normale și trapezoidale, utilizează reprezentarea prin alpha-cut și clasificarea bazată pe distanță și introduce metoda HACO. Algoritmul propus combină Ant Colony Optimization cu o mutație inspirată de GA și cu un mecanism de nerepetare de tip Tabu. Capitolul compară HACO cu GA, PSO, ABC și ACO standard folosind grafuri de referință simple, complexe și mari, evaluând iterațiile de convergență, timpul de convergență, timpul total de execuție, robustețea și semnificația statistică.

Capitolul 5 dezvoltă și evaluează stratul de predicție a oboselii și sănătății prin AI. Acesta prezintă seturile de date, preprocesarea, ingineria caracteristicilor, împărțirea pe subiecți, prevenirea scurgerilor de informație, metricile de performanță, modelarea ECG/HRV cu Random Forest, modelarea ochilor cu CNN, modelarea respirației cu Random

Forest, comparația între modalități, analiza de ablație, analiza erorilor orientată spre siguranță, fuziunea conștientă de calitate, orchestrarea inferenței online, tablourile de bord și evaluarea operațională conștientă de latență. Capitolul 5 este capitolul central de rezultate deoarece conectează modelele AI la arhitectura IoT/IIoT și transformă predicțiile în semnale de risc potrivite pentru alerte și suport decizional.

Capitolul 6 sintetizează concluziile, realizarea obiectivelor, contribuțiile principale, limitările, direcțiile viitoare, observațiile finale și valorificarea rezultatelor cercetării. Acesta confirmă că teza își atinge obiectivele la nivel de sistem, la nivel de optimizare, la nivel AI și la nivel de validare integrată. De asemenea, clarifică limitele lucrării, inclusiv validarea orientată pe software, utilizarea senzorilor prototip ca proxy-uri de semnal, eterogenitatea seturilor publice de date și necesitatea unor viitoare experimente în vehicule reale și la scară de flotă.

1.4 Metodologia cercetării

Metodologia combină cinci faze conectate: analiza, proiectarea arhitecturii, optimizarea conștientă de incertitudine, modelarea AI și validarea integrată. Această structură a fost necesară deoarece problema tezei nu poate fi rezolvată printr-o singură metodă: ea necesită atât implementare la nivel de sistem, cât și evaluare algoritmică.

Tabelul 2. Fazele metodologiei de cercetare și rezultatele obținute.

Fază	Acțiuni principale	Rezultate
Analiza literaturii	Cartografiere sistematică și analiză de tip SLR a IoT/IIoT, monitorizării șoferului și optimizării	Lacune, cerințe și obiective ale tezei
Proiectarea arhitecturii	Proiectare stratificată pentru detecție, comunicație, cloud, vizualizare și alertare	Cadru IoT/IIoT end-to-end și contract de telemetrie
Dezvoltarea optimizării	Formulare a drumului minim fuzzy mixt și proiectarea HACO	Nucleu de rutare conștient de incertitudine

Modelare AI	ECG/HRV RF, CNN pentru ochi, RF pentru respirație și fuziune multimodală	Modele de inferență a riscului de oboseală
Validare integrată	Analiza latenței, capacității de răspuns, convergenței, timpului de execuție, acurateței, F1 și ablației	Dovezi privind fezabilitatea, performanța și limitările

Metodologia cercetării urmează o progresie structurată, cu cinci faze majore: analitică, arhitecturală, optimizare algoritmică, modelare AI și validare experimentală. Faza analitică constă într-o analiză sistematică a stadiului actual al cercetării și într-o analiză a lacunelor. Aceasta investighează utilizarea sistemelor IoT/IIoT în ecosisteme EV, sănătatea și oboseala șoferului, arhitecturi edge-cloud, detecția multimodală și optimizarea sub incertitudine. Analiza utilizează căutări în baze de date, criterii de includere și excludere, clasificare tematică, extracția datelor și evaluarea calității. Această fază stabilește baza de dovezi și asigură faptul că sistemul propus răspunde unor limitări reale din literatura de specialitate [4-6].

Faza arhitecturală transpune cerințele identificate într-un cadru IoT/IIoT stratificat. Metodologia definește rolul funcțional al fiecărui strat: detecție și achiziție, preprocesare edge, comunicație, ingestie în cloud, procesarea fluxurilor, persistență, vizualizare, alertare și suport decizional. Arhitectura nu este tratată doar ca o diagramă de nivel înalt; aceasta este mapată pe servicii cloud și mecanisme de comunicație implementabile. MQTT este selectat ca protocol principal de telemetrie datorită modelului său publish-subscribe și adecvării pentru mesagerie continuă și ușoară, în timp ce HTTP este menținut ca rută secundară pentru compatibilitate și operații de tip cerere-răspuns. Timpul, structura mesajelor, câmpurile de payload, indicatorii de calitate și memoria tamponsunt considerate constrângeri de proiectare, nu elemente secundare [7-12].

Faza de optimizare dezvoltă un nucleu de rutare conștient de incertitudine. Problema este formulată ca un model de drum minim pe graf, în care ponderile arcelor sunt reprezentate ca numere fuzzy mixte. Acest lucru este important deoarece costurile de deplasare și decizie ale EV pot fi incerte din cauza traficului, consumului de energie, disponibilității încărcării, condițiilor de mediu și, potențial, riscului asociat stării șoferului. Teza utilizează procesarea alpha-cut și clasificarea costurilor fuzzy pentru a compara drumurile candidate. Metoda HACO este apoi proiectată pentru a îmbunătăți performanța căutării

prin combinarea construcției de drumuri ACO cu mutație și logică de nerepetare. Metoda este comparată cu GA, PSO, ABC și ACO în condiții comune și rulări repetate [13-16].

Faza de modelare AI dezvoltă fluxuri pentru inferența multimodală a sănătății și oboselei șoferului. Pentru ECG/HRV, metodologia include procesarea semnalului pe ferestre, detecția vârfurilor R, extracția caracteristicilor HRV, etichetarea euristică acolo unde adevărul de referință este limitat, clasificarea Random Forest, evaluarea pe subiecți și interpretarea importanței caracteristicilor. Pentru starea ochilor, metodologia include pregătirea setului de date, preprocesarea imaginilor, augmentarea, proiectarea unui CNN ușor, antrenarea, testarea și analiza matricei de confuzie. Pentru respirație, metodologia include definirea observațiilor, preprocesarea, selecția caracteristicilor, modelarea Random Forest, validarea încrucișată grupată și evaluarea orientată spre siguranță. Modelele sunt evaluate nu numai prin acuratețe, ci și prin precizie, recall, scor F1, rata fals-pozitive, rata fals-negative, acuratețe echilibrată și stabilitatea validării încrucișate [17-25].

O decizie metodologică centrală este împărțirea pe subiecți și prevenirea scurgerilor de informație. În monitorizarea șoferului, împărțirea aleatorie obișnuită poate supraestima performanța atunci când mostrele aceluiași șofer apar atât în antrenare, cât și în testare. Prin urmare, teza accentuează strategii de împărțire care reduc scurgerea de informație și reflectă mai bine generalizarea la șoferi noi. Această decizie este deosebit de importantă pentru semnalele fiziologice, unde diferențele individuale de bază pot domina sarcina de predicție. Prin combinarea evaluării rezistente la scurgeri cu comparații între seturi de date, teza oferă o interpretare mai realistă a performanței modelului și a riscului de implementare [17-19,25].

Faza de validare experimentală conectează metricile de sistem, optimizare și AI. La nivel de sistem, teza măsoară latența de încărcare, capacitatea de răspuns a alertelor, acuratețea detecției și robustețea în scenarii reprezentative precum conducere calmă, trafic intens, conducere nocturnă și frânare de urgență. La nivel de optimizare, măsoară iterațiile de convergență, timpul de convergență, timpul de execuție, robustețea și semnificația statistică. La nivel AI, măsoară performanța de testare, stabilitatea validării încrucișate și erorile orientate spre siguranță. Această validare pe mai multe niveluri este importantă deoarece un model cu acuratețe offline ridicată este insuficient dacă nu poate funcționa în limitele temporale, de calitate a datelor și de comunicație ale unui vehicul conectat [12,16,25].

Capitolul 2: Stadiul actual al cercetării privind IoT/IloT pentru vehicule electrice

Analiza stadiului actual al cercetării este sintetizată pe trei axe: arhitecturi IoT/IloT pentru ecosisteme EV, monitorizarea multimodală a sănătății șoferului și optimizarea în condiții de incertitudine. Analiza arată că aceste domenii sunt mature individual, dar insuficient conectate, ceea ce justifică cadrul integrat dezvoltat în teză [1-3,13-16].

Analiza stadiului actual arată că tehnologiile IoT și IloT sunt tot mai importante în ecosistemele EV. Platformele IoT sprijină colectarea telemetriei din sistemele bateriei, componentele transmisiei, senzori, comportamentul de încărcare, datele de localizare și variabilele legate de șofer. IloT adaugă cerințe legate de fiabilitate, scalabilitate, managementul ciclului de viață, interoperabilitate, supravegherea flotelor, mentenanță predictivă și integrarea cu infrastructura energetică. Totuși, analiza arată și că arhitecturile EV-IloT se concentrează adesea pe variabilele vehiculului și ale infrastructurii, tratând starea umană ca secundară, deși șoferul rămâne o componentă critică de siguranță în multe scenarii de operare EV [1].

Conectivitatea și selecția protocolelor sunt teme majore în literatura analizată. Sistemele EV pot utiliza comunicații în vehicul, comunicații vehicul-la-tot, API-uri cloud, mesagerie IoT și integrare între servicii. Pentru telemetria continuă, arhitecturile publicare-abonare precum MQTT sunt utile deoarece permit fluxuri de date ușoare între nodurile vehiculului, gateway-uri și servicii cloud. Pentru compatibilitate, configurare și apeluri discrete de servicii, comunicația bazată pe HTTP rămâne relevantă. Teza poziționează MQTT și HTTP ca opțiuni ingineresti complementare, nu concurente, MQTT fiind folosit ca rută principală pentru transmiterea telemetriei privind sănătatea șoferului, iar HTTP ca interfață secundară [7].

Calculul edge-cloud este un alt domeniu cheie. Procesarea edge poate reduce latența, proteja confidențialitatea și reduce lățimea de bandă, în timp ce procesarea cloud oferă stocare scalabilă, tablouri de bord, actualizarea modelelor, analiza flotelor și integrarea cu servicii externe. În monitorizarea sănătății șoferului, această împărțire este importantă deoarece unele alerte pot necesita răspuns local cu latență redusă, în timp ce analiza pe termen mai lung și monitorizarea flotei necesită resurse cloud. Teza utilizează acest principiu pentru a defini un sistem în care achiziția locală și logica preliminară coexistă cu ingestia în cloud, analiza de flux, persistența în baze de date, vizualizarea și alertarea la distanță [8,9]. Aceeași arhitectură conectată necesită, de asemenea, guvernanta de securi-

tate cibernetică, identitate sigură a dispozitivelor, transfer criptat al datelor și acces controlat atunci când informațiile privind sănătatea șoferului sunt procesate între vehicul, și servicii edge și cloud [10,11].

Analiza monitorizării sănătății și oboselii șoferului arată că nicio modalitate de detecție nu este suficientă în toate condițiile. Sistemele bazate pe ochi pot captura clipirea, închiderea pleoapelor, privirea și semne vizuale de somnolență, dar pot eșua în condiții de iluminare slabă, ocluzie, ochelari sau probleme de poziționare a camerei. Semnalele fiziologice, precum ECG/HRV, pot oferi dovezi mai profunde ale oboselii sau stării cognitive, dar pot fi afectate de artefacte de mișcare, calitatea contactului electrodului și variabilitate individuală. Respirația poate reflecta schimbări legate de stres și oboseală, însă adesea se suprapune puternic între clase și poate fi nesigură ca detector independent. Aceste observații motivează accentul tezei pe dovezi multimodale și fuziune conștientă de calitate [2,3,17,22].

Analiza abordărilor de învățare automată și învățare profundă arată un peisaj divers al modelelor Random Forest, SVM, kNN, CNN, recurente, învățării prin transfer și strategiilor de fuziune multimodală.. Multe lucrări raportează acuratețe ridicată, dar comparabilitatea este limitată de seturi de date, etichete, împărțiri de evaluare, metrici și condiții controlate diferite. Teza răspunde prin raportarea mai multor metrici, utilizarea evaluării pe subiecți acolo unde este posibil, compararea modalităților și interpretarea indicatorilor orientați spre siguranță, precum rata fals negativă. Acest aspect este important deoarece evenimentele de oboseală ratate pot fi mai periculoase decât alarmele false în monitorizarea critică pentru siguranță [3,23,24].

Analiza optimizării în sistemele EV arată că rutarea EV și alocarea resurselor sunt influențate frecvent de timpul de deplasare, consumul de energie, disponibilitatea stațiilor de încărcare, starea bateriei, traficul, ferestrele de timp și incertitudine. Formulările fuzzy și metaeuristicele sunt utile atunci când formulările deterministe exacte sunt insuficiente sau costisitoare computațional. Teza se bazează pe acest fundal, dar adaugă o perspectivă importantă: deciziile de rutare și de resurse trebuie să poată primi riscul privind sănătatea șoferului ca intrare. Prin urmare, nucleul de optimizare HACO nu este doar un exercițiu de referință; el este poziționat ca un serviciu reutilizabil care poate accepta ulterior penalizări sau constrângeri de risc din stratul de monitorizare a șoferului [13-16].

Capitolul 3 - Arhitectura și implementarea sistemului IoT/IIoT pentru monitorizarea sănătății șoferului

Arhitectura propusă este unul dintre rezultatele originale centrale ale tezei. Aceasta transformă datele multimodale privind sănătatea șoferului în telemetrie structurată, care poate fi procesată prin logică locală, comunicație MQTT/HTTP, servicii cloud Azure, tablouri de bord și alerte. Figurile 1-4 și Tabelul 3 sintetizează fluxul de lucru, implementarea cloud, răspunsul operațional și latența de încărcare a telemetriei pentru prototip [12,25].




Figura 1. Fluxul integrat al tezei: detecție, cloud, AI și decizie.




Figura 2. Arhitectura cloud pentru telemetria IoT și tablouri de bord.

Tabelul 3. Evaluarea operațională a prototipului de monitorizare IoT/cloud.

Scenariu	Latență de încărcare (ms)	Acuratețea de detecției (%)	Răspuns alertă (ms)	Observație
Conducere calmă	180	95	250	Performanță stabilă
Trafic intens	250	92	300	Întârzieri ușoare sub sarcină
Conducere nocturnă	200	93	270	Detecție consecventă
Frânare de urgență	150	94	220	Răspuns rapid la eveniment critic




Figura 3. Răspunsul end-to-end al alertelor în scenarii reprezentative de conducere.




Figura 4. Latența de încărcare a telemetriei în scenarii reprezentative de conducere.

Latența de încărcare a telemetriei rămâne în intervalul 150-250 ms, cea mai mare întârziere apărând în trafic intens, iar cea mai mică în timpul frânării de urgență, susținând fezabilitatea aproape în timp real a conduitei IoT/cloud.

Contribuția la nivel de sistem a tezei este o arhitectură IoT/IIoT end-to-end pentru monitorizarea sănătății șoferului în EV-uri conectate. Arhitectura este stratificată, modulară și orientată spre implementare. Straturile sale principale sunt detecția și achiziția multimodală, preprocesarea locală, comunicația edge/gateway, ingestia în cloud, procesarea fluxurilor, stocarea persistentă, vizualizarea, alertarea și feedbackul în buclă închisă. Arhitectura tratează monitorizarea sănătății șoferului ca un serviciu EV care trebuie să satisfacă cerințe ingineresti precum interoperabilitatea, trasabilitatea, controlul temporal, calitatea datelor, securitatea și scalabilitatea [12].

La stratul de senzorică, teza ia în considerare dovezi multimodale legate de activitatea cardiacă, comportamentul ochilor și respirație. În arhitectura prototipului, componente cu cost redus sunt folosite ca proxy-uri de semnal pentru a valida achiziția datelor, formatarea pachetelor, comunicația și integrarea cloud. Aceasta este o limitare și o alegere de proiectare importantă: senzorii prototip nu sunt prezentați ca instrumente clinice, ci ca proxy-uri ingineresti pentru demonstrarea traseului complet al datelor. În implementările viitoare, aceștia ar fi înlocuiți sau completați de senzori ECG, camere, senzori de respirație și telemetrie vehiculară de nivel de producție. Valoarea prototipului constă în faptul că dovedește arhitectura și logica de gestionare a datelor înaintea unei validări costisitoare pe vehicul real [12].

Stratul de achiziție definește un format reproductibil al pachetelor și recomandă cadențe de actualizare a caracteristicilor pentru diferite modalități. Sistemul utilizează marce temporale, identificatori de dispozitiv, numere de secvență, etichete de stare și indicatori de calitate. Aceste câmpuri sprijină trasabilitatea și sincronizarea, mai ales atunci când datele pot fi întârziate, lipsă, duplicate sau afectate de zgomotul senzorilor. Teza subliniază că inferența privind sănătatea șoferului în vehicule conectate necesită mai mult decât măsurători brute; aceasta necesită telemetrie structurată care permite sistemului să știe când au fost colectate datele, de unde provin, dacă sunt valide și cum trebuie aliniate cu alte modalități [12].

Proiectarea comunicației utilizează MQTT ca protocol principal și HTTP ca protocol secundar. MQTT este adecvat pentru telemetrie continuă deoarece sprijină schimbul de date publicare-abonare ușor și rutarea bazată pe subiecte. HTTP este util pentru compatibilitate, testare, configurare și comunicații de tip REST. Teza definește scheme de subiecte, câmpuri de payload, variante de gateway și constrângeri temporale. De asemenea, ia în considerare latența, pierderea pachetelor, jitterul, bufferingul și transmiterea etapizată după întreruperi. Această abordare reflectă constrângeri IoT/IIoT reale: un sistem care funcționează doar în condiții perfecte de conectivitate nu este suficient pentru mobilitatea conectată [7].

Implementarea cloud utilizează Azure IoT Hub ca gateway de telemetrie, Azure Stream Analytics pentru parsare, ferestre temporale și rutare, Azure Cosmos DB pentru persistența telemetriei și a evenimentelor și Power BI pentru vizualizare. Această descompunere a serviciilor oferă arhitecturii o realizare cloud practică. IoT Hub gestionează ingestia dispozitiv-la-cloud și identitatea dispozitivelor. Stream Analytics procesează evenimentele și sprijină logica pe ferestre. Cosmos DB stochează telemetria și alertele într-un model de document scalabil. Power BI oferă tablouri de bord pentru monitorizarea stării șoferului, calității senzorilor, comportamentului scenariilor și stării evenimentelor [12].

Sistemul a demonstrat comportament operațional aproape în timp real în scenarii reprezentative. Latența de încărcare a variat între 150 și 250 ms, cu 180 ms la conducere calmă, 250 ms în trafic intens, 200 ms la conducere nocturnă și 150 ms la frânare de urgență. Răspunsul la alerte a variat între 220 și 300 ms, cu cea mai mare întârziere în trafic intens și cel mai rapid răspuns la frânarea de urgență. Acuratețea detecției sau anomaliei din tabelul scenariilor a variat între 92% și 95%. Aceste rezultate indică faptul că arhitectura este potrivită pentru monitorizare cu lățime de bandă redusă, integrată în cloud, și poate genera avertizări la timp în condiții reprezentative [12].

Capitolul 4: Optimizare metaeuristică hibridă în condiții de incertitudine

Capitolul 4 oferă componenta de optimizare conștientă de incertitudine a tezei. Acesta formulează rutarea ca o problemă de drum minim cu ponderi fuzzy mixte pe arce și propune HACO ca soluție metaeuristică hibridă rapidă. Fig. 5, 6 și 7 și Tabelul 4 sintetizează logica algoritmică, comportamentul de convergență și principalele rezultate privind convergența și timpul de execuție [13-16].




Figura 5. Diagrama de flux a algoritmului HACO.




Figura 6. Comportamentul de convergență al HACO și al algoritmilor de referință pentru graful simplu.

Graficul de convergență ilustrează stabilizarea rapidă a HACO comparativ cu GA, PSO, ABC și ACO standard, susținând vizual reducerile numerice ale timpului de convergență și ale timpului de execuție raportate în Tabelul 4.

Tabelul 4. Rezultatele de convergență și timp de execuție ale HACO pentru grafurile de referință.

Graf	Iterații conv.	Timp până la convergență (s)	Timp de execuție (s)	Reducere timp execuție vs. ACO
Simplu	1.8	0.013	0.074	91.40%
Complex	2.0	0.031	0.17	95.11%
Mare	7.0	0.083	0.18	96.73%




Figura 7. Timpul mediu până la convergență în funcție de dimensiunea grafului de referință.

Partea de optimizare a tezei abordează nevoia de suport decizional în condiții operaționale EV incerte. Timpul de deplasare, consumul de energie, congestia traficului, disponibilitatea încărcării și riscul asociat stării șoferului pot fi toate incerte. Pentru a modela acest tip de incertitudine, Capitolul 4 formulează problema drumului minim folosind ponderi fuzzy mixte pe arce. Modelul pe graf reprezintă noduri și arce, iar ponderile arcelor pot fi exprimate prin numere fuzzy normale și trapezoidale. Reprezentarea α -cut și agregarea permit calcularea costurilor fuzzy ale drumurilor, iar clasificarea bazată pe distanță permite compararea drumurilor candidate [13,14,16].

Soluția propusă este algoritmul Hybrid Ant Colony Optimization, HACO. ACO standard este eficient pentru probleme pe grafuri deoarece utilizează construirea probabilistică a drumurilor candidate ghidată de feromoni. Totuși, ACO standard poate suferi de convergență prematură, drumuri repetate și diversificare limitată. HACO îmbunătățește căutarea prin combinarea construcției de drumuri ACO cu un operator de mutație inspirat de GA și un criteriu de nerepetare de tip Tabu. Mecanismul de mutație sprijină explorarea prin modificarea drumurilor repetate sau stagnante, în timp ce regula de nerepetare descurajează revizitarea inefficientă a acelorași tipare de soluții. Actualizarea feromonilor consolidează apoi drumurile candidate bune, iar evaporarea previne blocarea prea timpurie a sistemului în soluții suboptimale [15,16].

Proiectarea experimentală compară HACO cu Genetic Algorithm, Particle Swarm Optimization, Artificial Bee Colony și ACO standard. Algoritmii sunt evaluați pe trei grafuri de referință: un graf simplu cu 11 noduri și 25 de arce, un graf complex cu 23 de noduri și 40 de arce și un graf mare cu 30 de noduri și 71 de arce. Pentru toți algoritmii, protocolul de evaluare comparativă utilizează codare, evaluarea obiectivului, setări de parametri, dimensiuni ale populației, bugete de iterații, rulări repetate comune și aceleași metrici: iterații de convergență, timp de convergență și timp total de execuție [16].

Rezultatele arată că HACO a obținut cel mai bun comportament de convergență și cel mai mic timp de execuție pentru toate dimensiunile grafurilor de referință. În graful simplu, HACO a atins o medie de 1.8 iterații de convergență, 0.013 s timp de convergență și 0.074 s timp de execuție. În graful complex, a atins 2.0 iterații, 0.031 s timp de convergență și 0.17 s timp de execuție. În graful mare, a atins 7.0 iterații, 0.083 s timp de convergență și 0.18 s timp de execuție. Aceste rezultate sunt substanțial mai bune decât algoritmii de bază, mai ales pentru timpul până la convergență și timpul total de execuție [16].

Comparativ cu ACO standard, HACO a redus iterațiile de convergență cu 40.0% în graful simplu, cu 20.0% în graful complex și cu 23.6% în graful mare. A redus timpul până la convergență cu 91.33%, 95.00% și 90.24% pentru cele trei grafuri și a redus timpul de execuție cu 91.40%, 95.11% și 96.73%. Aceste îmbunătățiri arată că strategia de hibridizare oferă un beneficiu practic, nu doar o modificare teoretică. Mecanismele de mutație și nerepetare ajută HACO să mențină explorarea, păstrând în același timp punctele forte ale ACO în construirea drumurilor [16].

Analiza robusteții susține, de asemenea, concluzia. Pentru rezultatele de referință, HACO a arătat deviație standard redusă pentru iterațiile de convergență, timpul de convergență și timpul de execuție. Testarea statistică a confirmat că diferențele dintre algoritmi au fost semnificative. Testul Kruskal-Wallis a returnat $H = 15.67$ cu $p < 0.01$, iar comparațiile post-hoc Dunn au arătat diferențe pereche semnificative între HACO și GA, PSO, ABC și ACO pentru timp și iterații. Aceasta confirmă că superioritatea HACO în benchmarkul raportat este semnificativă statistic [16].

Relevanța HACO în cadrul tezei este mai largă decât rezolvarea unei probleme abstracte de drum minim. Acesta stabilește un nucleu de rutare conștient de incertitudine care poate fi conectat la monitorizarea sănătății șoferului. După ce stratul AI estimează oboseala sau riscul de sănătate, stratul de optimizare poate utiliza acest risc ca penalizare suplimentară, constrângere sau declanșator de rerutare. Astfel se creează o relație în buclă închisă între detecție și acțiune: vehiculul sau sistemul de flotă nu doar detectează o condiție a șoferului, ci o poate utiliza pentru a sprijini decizii mai sigure în condiții incerte de trafic și operare [16,25].

Capitolul 5 - Predicția oboselii/sănătății prin AI și evaluarea integrată

Capitolul 5 dezvoltă și evaluează stratul de inferență AI al tezei utilizând indicatori de oboseală bazați pe ECG/HRV, analiza ochilor și respirație. Scopul este de a detecta sau prezice oboseala și riscul legat de sănătatea șoferului din date multimodale, de a determina care modalități sunt suficient de fiabile pentru implementare și de a operaționaliza ieșirile acestora în cadrul conducerii de monitorizare IoT/IloT. Evaluarea este orientată spre implementare și utilizează observații pe ferestre temporale, împărțire pe subiecți acolo unde este posibil, raționament conștient de calitate, matrice de confuzie și mai multe metrice care reflectă atât acuratețea predictivă, cât și relevanța pentru siguranță [17-25]. Fluxul metodologic utilizat pentru detecția oboselii pe baza semnalelor ECG/HRV este prezentat în Figura 8, iar performanțele principalelor modalități de detecție și interpretarea lor din perspectiva siguranței sunt sintetizate în Tabelul 5.




Figura 8. Fluxul de detecție a oboselii bazat pe ECG/HRV, adaptat din fluxul de lucru al tezei.

Tabelul 5. Performanța AI multimodală și interpretarea din perspectiva siguranței.

Modalitate	Set de date/configurație	Acuratețe	Scor F1	Interpretare
ECG/HRV (RF)	OpenDriver	0.964	0.958	Canal fiziologic primar puternic
ECG/HRV (RF)	MAUS	0.8095	0.826	Util, dar sensibil la context
Ochi (CNN)	YawDD	0.93	0.93	Canal comporta- mental primar puternic

Ochi (CNN)	TinyML Eye	0.92	0.92	Performanță stabilă și echilibrată
Respirație (RF)	Set de date pentru respirație	0.46	0.43-0.51	Doar auxiliară; risc ridicat de fals negative




Figura 9. Compararea acurateței și scorului F1 între modalitățile de senzorială.




Figura 10. Matrice de confuzie reprezentative pentru detecția oboselii bazată pe ECG/HRV, ochi și respirație.

Matricele de confuzie clarifică interpretarea din perspectiva siguranței: modelele bazate pe ECG/HRV și ochi prezintă comportament de clasificare echilibrat, în timp ce modelul bazat exclusiv pe respirație ratează multe cazuri de oboseală, confirmând de ce respirația este tratată ca dovadă auxiliară și nu ca detector principal.

Fluxul ECG/HRV utilizează caracteristici fiziologice extrase din electrocardiogramă sau din variabilitatea ritmului cardiac. Fluxul include preprocesare, detecția vârfurilor R, ingineria caracteristicilor, etichetarea euristică a oboselii în condițiile lipsei referinței de adevăr. , clasificarea Random Forest și analiza între seturi de date. ECG/HRV este tratat ca un canal fiziologic primar deoarece poate captura modificări ale reglării autonome și ale variabilității asociate oboselii. În același timp, teza recunoaște că ECG/HRV este sensibil la calitatea contactului, artefacte de mișcare și diferențe individuale de bază. De aceea, evaluarea pe subiecți și indicatorii de calitate sunt importanți [17,23,25].

Cel mai puternic rezultat ECG/HRV a fost obținut pe setul de date OpenDriver. Modelul Random Forest a atins 97.6% acuratețe medie de validare încrucișată, 96.4% acuratețe pe test și 95.8% scor F1. Aceste rezultate indică faptul că caracteristicile ECG/HRV oferă separabilitate puternică în cadrul real de conducere evaluat. Pe MAUS, aceeași modalitate a produs performanță mai scăzută, dar încă utilă, cu 80.95% acuratețe pe test și 82.61% scor F1. Această reducere este importantă deoarece arată sensibilitatea la context: tipul de oboseală, condițiile sarcinii, etichetele și construcția setului de date afectează puternic performanța modelului. Pe DriveDB, performanța pe subiecți a arătat rezultate medii ridicate pentru subiecții selectați, dar teza tratează cu atenție numărul mic de subiecți și evită supraestimarea generalizării [18,19,23,25].

Fluxul de modelare bazat pe ochi utilizează o rețea neuronală convoluțională ușoară pentru a detecta modele vizuale legate de oboseală din imaginile stării ochilor. Dovezile bazate pe ochi sunt atractive operațional deoarece camerele sunt tot mai prezente în vehiculele moderne și pot captura indicatori comportamentali precum închiderea ochilor și somnolența. Teza evaluează modelul pe seturile de date YawDD și TinyML Eye. CNN-ul a obținut 92.56% acuratețe, 91.89% precizie, 92.94% recall și 92.41% scor F1 pe YawDD. Pe TinyML Eye, a obținut 92.18% acuratețe, 92.36% precizie, 91.94% recall și 92.15% scor F1. Aceste valori arată performanță stabilă și echilibrată pe două seturi de date asociate ochilor [20,21,24,25].

Metricile derivate ale erorilor întăresc această interpretare. Pentru YawDD, specificitatea a fost 0.922, valoarea predictivă negativă 0.932, acuratețea echilibrată 0.926, coeficientul Matthews 0.851, rata fals pozitivă 0.078 și rata fals negativă 0.071. Pentru TinyML Eye, specificitatea a fost 0.924, valoarea predictivă negativă 0.920, acuratețea echilibrată 0.922, MCC 0.844, FPR 0.076 și FNR 0.081. Aceste rezultate arată că modelul ochilor nu

este doar precis, ci și echilibrat între alarme false și evenimente de oboseală ratate [20,21,24,25].

Modelul bazat pe respirație a produs cele mai slabe rezultate ca modalitate independentă. Acuratețea medie a validării încrucișate grupate a fost 0.708, cu deviație standard 0.187, indicând generalizare instabilă între folduri. În setarea de test reținută, modelul Random Forest a obținut doar 46% acuratețe. Pentru clasa oboseală, precizia a fost 1.00, dar recall-ul a fost doar 0.24, cu scor F1 de 0.39. Indicatorii derivați din matricea de confuzie au arătat specificitate 1.000, sensibilitate 0.244, rată fals negativă 0.756, valoare predictivă negativă 0.347, acuratețe echilibrată 0.622 și MCC 0.291. Aceasta înseamnă că modelul a ratat frecvent evenimente reale de oboseală, ceea ce este inacceptabil dacă este utilizat ca detector principal de siguranță [22,23,25].

Comparația între modele oferă unul dintre cele mai importante rezultate ale tezei. Modelele ECG/HRV și ochi sunt ambele canale primare puternice, dar oferă tipuri diferite de dovezi. ECG/HRV oferă caracteristici fiziologice interpretabile, precum variabilitatea RR și descriptorii statistici, în timp ce CNN-urile pentru ochi oferă dovezi comportamentale din tipare vizuale învățate. Respirația are interpretabilitate medie, dar separabilitate independentă slabă în setul de date evaluat. Prin urmare, teza recomandă o strategie de fuziune conștientă de calitate, în care ECG și ochii sunt canalele principale, iar respirația este utilizată doar ca dovadă auxiliară atunci când calitatea semnalului și încrederea sunt suficiente [3,17,20-22,25].

Analiza de ablație confirmă această recomandare. ECG singur a atins 0.964 acuratețe și 0.958 scor F1. Ochiul singur a atins 0.930 acuratețe și 0.930 scor F1. Respirația singură a produs doar 0.460 acuratețe și scor F1 dependent de clasă în jur de 0.430-0.510. Combinarea ECG și ochi a îmbunătățit performanța la 0.978 acuratețe și 0.969 scor F1. Adăugarea respirației a produs doar un câștig marginal, ajungând la 0.981 acuratețe și 0.972 scor F1. Rezultatul este util științific deoarece nu raportează simplu că „mai mulți senzori sunt mai buni”; el arată că numai senzorii de calitate înaltă și complementari trebuie să domine decizia de fuziune [25].

Analiza erorilor orientată spre siguranță este, de asemenea, centrală. ECG-OpenDriver a avut aproximativ 0.038 rată fals pozitivă, 0.034 rată fals negativă și 0.964 acuratețe echilibrată. ECG-MAUS a avut aproximativ 0.167 FPR, 0.208 FNR și 0.812 acuratețe echilibrată. Eye-YawDD a avut aproximativ 0.078 FPR, 0.071 FNR și 0.926 acuratețe echili-

brată. Eye-TinyML a avut aproximativ 0.076 FPR, 0.081 FNR și 0.922 acuratețe echilibrată. Respirația a avut 0.000 FPR, dar aproximativ 0.756 FNR și 0.622 acuratețe echilibrată. Deoarece fals negativele reprezintă evenimente de oboseală ratate, aceste rezultate justifică clar de ce respirația nu trebuie utilizată ca detector dominant în configurația actuală [25].

Partea finală a Capitolului 5 integrează rezultatele AI în sistemul IoT/cloud în timp real. Ieșirile modelelor sunt tratate ca evenimente care pot fi ingerate, stocate, vizualizate și utilizate pentru alerte. Evaluarea operațională utilizează scenarii de conducere calmă, trafic intens, conducere nocturnă și frânare de urgență. Latența de încărcare a variat între 150 și 250 ms, acuratețea detecției între 92% și 95%, iar răspunsul la alerte între 220 și 300 ms. Aceste valori confirmă faptul că stratul AI este compatibil cu calea de monitorizare dezvoltată în Capitolul 3. Prin urmare, teza validează nu numai clasificarea offline, ci și fezabilitatea operațională end-to-end [12,25].

Capitolul 6: Concluzii și direcții viitoare

6.1 Rezultate originale, contribuții și relevanță

Contribuțiile originale ale tezei pot fi grupate în patru rezultate principale: arhitectura IoT/IloT pentru sănătatea șoferului, metoda de optimizare HACO, evaluarea AI multi-modală și regula de fuziune, precum și fluxul de validare integrată. Tabelul 6 sintetizează aceste contribuții înainte de discutarea lor detaliată [12,16,25].

Tabelul 6. Contribuții originale și relevanță la nivel de teză.

Contribuție	Rezultat original	Relevanță
Arhitectură IoT/IloT	Cadru cloud-edge stratificat pentru monitorizarea sănătății șoferului, cu contract de telemetrie și tablouri de bord	Transformă sănătatea șoferului într-un serviciu EV conectat
Optimizare HACO	ACO hibrid cu mutație inspirată de GA și nerepetare de tip Tabu pentru drumuri minime fuzzy mixte	Permite suport rapid de rutare conștient de incertitudine
Modele AI multimodale	ECG/HRV RF, CNN pentru ochi, RF pentru respirație și fuziune conștientă de calitate	Oferă inferență practică a riscului de oboseală, cu interpretare specifică modalității
Validare integrată	Dovezi privind latența, răspunsul la alerte, convergența, timpul de execuție, acuratețea, F1 și ablația	Conectează fezabilitatea sistemului cu performanța algoritmică

Primul rezultat original este dezvoltarea unei arhitecturi IoT/IloT implementabile, în care monitorizarea sănătății șoferului este tratată ca serviciu EV central. Arhitectura definește fluxul complet de la detecție la acțiune: achiziție multimodală, preprocesare locală, telemetrie structurată, comunicație MQTT/HTTP, ingestie în cloud, procesarea fluxurilor, stocare, vizualizare, alerte și feedback. De asemenea, specifică scheme de mesaje, constrângeri temporale, identitatea dispozitivului, securitatea transportului, indicatori de calitate a datelor și descompunerea serviciilor cloud. Aceasta oferă tezei o contribuție puter-

nică de inginerie , deoarece depășește o diagramă conceptuală și prezintă o arhitectură implementabilă [12].

Al doilea rezultat original este algoritmul HACO pentru optimizarea drumului minim cu ponderi fuzzy mixte. HACO combină căutarea ACO, mutația inspirată de GA și un mecanism de nerepetare de tip Tabu pentru a îmbunătăți explorarea și a evita convergența prematură. Rezultatele sale pe grafuri de referință simple, complexe și mari arată reduceri majore ale timpului de convergență și ale timpului de execuție comparativ cu ACO standard și alte metaeuristici. Prin urmare, algoritmul contribuie la suportul decizional EV conștient de incertitudine și poate acționa ca primitivă de rutare pentru optimizarea viitoare conștientă de sănătatea șoferului [16].

Al treilea rezultat original este evaluarea AI multimodală pentru predicția oboselii și sănătății șoferului. Teza oferă o analiză comparativă a modelelor ECG/HRV, ochi și respirație folosind mai multe seturi de date și metrici. Aceasta arată că dovezile ECG/HRV și ochi formează combinația primară preferată, în timp ce respirația trebuie tratată ca auxiliară în configurația actuală. Această concluzie este importantă deoarece se bazează atât pe performanța predictivă, cât și pe analiza erorilor orientată spre siguranță. Teza nu supraestimează cel mai slab model; în schimb, transformă limitările empirice într-o regulă practică de fuziune [17-25].

Al patrulea rezultat original este validarea integrată. Teza conectează arhitectura, optimizarea și modelele AI într-un singur flux de lucru. Arhitectura cloud-edge oferă canalul operațional, HACO oferă nucleul de optimizare, iar modelele AI oferă semnale de risc. Această integrare sprijină un concept în buclă închisă în care observațiile privind starea șoferului pot influența alertele, tablourile de bord și constrângerile de rutare sau decizie. Contribuția rezultată nu este doar o colecție de metode, ci un cadru pentru operarea EV conectată conștientă de sănătate [12,16,25].

Contribuția tezei la domeniu este, prin urmare, atât la nivel de sistem, cât și la nivel metodologic. La nivel de sistem, aceasta oferă o arhitectură pentru monitorizarea în timp real a sănătății șoferului în ecosisteme EV conectate. La nivel metodologic, oferă un model metaeuristic hibrid de înaltă performanță și modele AI validate, pentru inferența oboselii.. La nivel de integrare, demonstrează cum predicțiile de risc pot deveni evenimente acționabile într-o arhitectură IoT/IIoT cloud-edge. Acest lucru este relevant pentru siguranța EV, monitorizarea flotelor, sistemele inteligente de transport, serviciile de mobilitate conec-

tate la cloud și viitoare platforme vehiculare care combină conștientizarea stării umane cu luarea deciziilor operaționale [1,12,16,25].

Cercetarea contribuie și prin clarificarea limitărilor. Senzorii prototip sunt tratați ca proxy-uri de semnal, nu ca instrumente medicale. Rezultatele AI se bazează pe seturi publice de date cu condiții eterogene și, în unele cazuri, etichete proxy. Modelarea bazată exclusiv pe respirație se dovedește slabă și cu multe rezultate fals negativ. Securitatea și confidențialitatea sunt abordate arhitectural prin criptare, identitate și acces controlat, dar nu prin metode criptografice noi sau fluxuri complete de conformitate. Aceste limitări sunt importante deoarece fac concluziile tezei realiste și definesc pașii următori necesari înaintea unei implementări complete în vehicul sau la nivel de flotă [10-12,17-25].

6.2 Concluzii generale și direcții viitoare

Concluziile sintetizează teza pe trei niveluri: implementarea sistemului, performanța optimizării și predicția oboselii bazată pe AI. Paragrafele următoare explică modul în care au fost atinse obiectivele și ce direcții viitoare sunt necesare înaintea implementării complete în vehicule sau flote.

Concluzia principală a tezei este că sănătatea șoferului poate fi integrată ca serviciu IoT/IIoT de prim rang în ecosistemele vehiculelor electrice conectate. Cadrul propus conectează detecția, comunicația, procesarea în cloud, inferența AI, vizualizarea, alertarea și optimizarea conștientă de incertitudine. Acesta arată că monitorizarea șoferului nu trebuie să fie un clasificator izolat, ci o parte a unei bucle operaționale mai largi, în care riscul detectat sau prezis poate sprijini deciziile. Această concluzie răspunde direct problemei principale și confirmă valoarea integrării conectivității vehiculului, detecției stării șoferului, analizei de tip cloud-edge și optimizării [1,12,16,25].

Obiectivul la nivel de sistem a fost atins prin implementarea și validarea arhitecturii de monitorizare IoT/IIoT. Arhitectura a arătat comportament aproape în timp real, cu latență de încărcare între 150 și 250 ms și răspuns la alerte între 220 și 300 ms. Aceste valori indică fezabilitate practică pentru monitorizarea integrată în cloud, mai ales atunci când este combinată cu logică locală pentru evenimente critice. Teza a demonstrat, de asemenea, că telemetria structurată, indicatorii de calitate și descompunerea serviciilor sunt necesare pentru implementare fiabilă [12].

Obiectivul de optimizare a fost atins prin dezvoltarea și evaluarea comparative realizată pentru HACO. Algoritmul a obținut cel mai mic timp de convergență și cel mai mic timp de execuție dintre algoritmi comparați și a arătat îmbunătățiri semnificative statistice. Aceasta confirmă că proiectarea metaeuristică hibridă poate îmbunătăți performanța rutării conștiente de incertitudine. Mai important, stratul de optimizare este compatibil cu ideea tezei de suport decizional conștient de sănătatea șoferului, deoarece scorurile de risc din stratul AI pot fi adăugate ca penalizări, constrângeri sau modificatori de selecție a traseului [16].

Obiectivul AI a fost atins prin modele multimodale de predicție a oboselii și sănătății. Modelele ECG/HRV și ochi au arătat performanțe predictive puternice, în timp ce respirația s-a dovedit nepotrivită ca detector principal în configurația evaluată. Cele mai bune rezultate de fuziune au fost obținute prin combinarea ECG și ochi, toate modelele împreună producând doar o îmbunătățire marginală. Aceasta susține concluzia că sistemele multimodale trebuie să fie selective și conștiente de calitate, nu să combine simplu fiecare semnal disponibil [17-25].

Direcțiile viitoare trebuie să mute arhitectura de la validarea orientată pe software către implementarea în vehicule reale și flote. Aceasta necesită senzori de nivel de producție, înregistrări de lungă durată, populații variate de șoferi, tipuri diferite de vehicule și condiții de teren care includ vibrații, schimbări de iluminare, întreruperi de conectivitate și diversitate a șoferilor. De asemenea, trebuie incluse modele AI multimodale mai avansate, estimări calibrate ale incertitudinii, linii de bază personalizate, metode de explicabilitate, inferență eficientă la edge, învățare cu păstrarea confidențialității și o cuplare mai puternică între riscul prezis al șoferului și politicile de rutare/resurse [10-12,17-25].

Cercetările viitoare trebuie să extindă, de asemenea, HACO și stratul de suport decizional dincolo de problemele de referință de tip drum minim. Formulările viitoare pot integra consumul real de energie al EV, disponibilitatea stațiilor de încărcare, riscul traseului, evoluția oboselii șoferului, necesarul de odihnă, incertitudinea traficului și constrângerile la nivel de flotă. În acest fel, componenta de optimizare poate evolua de la o primitivă de rutare conștientă de incertitudine la un instrument complet de planificare EV conștient de sănătate [13-16].

6.3 Valorificarea rezultatelor cercetării

Valorificarea rezultatelor cercetării confirmă faptul că teza a produs rezultate științifice atât teoretice, cât și aplicate. Aceste rezultate susțin fundamentul de analiză, prototipul IoT/cloud, contribuția de optimizare HACO și cadrul final multimodal AI pentru oboseala șoferului [1,12,16,25].

Cercetarea din teză a fost valorificată prin mai multe rezultate științifice directe și complementare. Fundamentul orientat spre analiză este susținut de publicația „The Role of the Industrial IoT in Advancing Electric Vehicle Technology: A Review”, care contribuie la sinteza stadiului actual al cercetării și susține justificarea tratării sănătății șoferului ca serviciu de prim rang în ecosistemele EV. Arhitectura sistemului este susținută de lucrarea „IoT-Enabled Driver Health Monitoring System Using Multi-Modal Sensors and Cloud Integration”, care contribuie direct la Capitolul 3 prin arhitectura de monitorizare multimodală cu cost redus, detecția bazată pe ESP32, comunicația MQTT/HTTP, conectivitatea Azure IoT Hub, vizualizarea și detecția anomaliilor la nivel cloud [1,12].

Contribuția de optimizare este susținută de lucrarea din Alexandria Engineering Journal „A novel Hybrid ant colony algorithm for solving the shortest path problems with mixed fuzzy arc weights”, care formează nucleul Capitolului 4 și oferă formularea HACO, comparațiile de referință și analiza performanței. Contribuția AI și de monitorizare integrată este susținută de „A Hybrid Machine Learning and IoT System for Driver Fatigue Monitoring in Connected Electric Vehicles”, care formează baza principală a Capitolului 5 și contribuie cu modelarea ECG/HRV, analiza stării ochilor, evaluarea respirației, analiza fuziunii și logica de implementare conectată la cloud [16,25].

Publicațiile suplimentare au contribuit la dezvoltarea științifică mai largă a activității doctorale, mai ales în AI, optimizare metaeuristică și modelare predictivă hibridă. Aceste lucrări complementare au consolidat maturitatea metodologică necesară pentru construcția modelelor, evaluarea comparativă, interpretarea performanței și integrarea inginerescă interdisciplinară. În ansamblu, valorificarea demonstrează o corespondență coerentă între rezultatele publicate și capitolele tezei: Capitolul 2 este susținut de articolul de review pentru IIoT/EV, Capitolul 3 de sistemul de monitorizare IoT-enabled, Capitolul 4 de lucrarea de optimizare HACO, iar Capitolul 5 de lucrarea privind sistemul hibrid de învățare automată și IoT pentru monitorizarea oboselii șoferului. Împreună, aceste rezultate confirmă originalitatea, relevanța și forța de diseminare a cercetării [1,12,16,25].

Referințe

1. AlHousrya, O., et al., The Role of the Industrial IoT in Advancing Electric Vehicle Technology: A Review. *Applied Sciences*, 2025. 15(17): 9290.
2. Albadawi, Y., Takruri, M., and Awad, M., A review of recent developments in driver drowsiness detection systems. *Sensors*, 2022. 22(5): 2069.
3. Baltrušaitis, T., Ahuja, C., and Morency, L.-P., Multimodal machine learning: A survey and taxonomy. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018. 41(2): 423-443.
4. Page, M.J., et al., The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*, 2021. 372.
5. Keele, S., Guidelines for performing systematic literature reviews in software engineering. Technical Report, 2007.
6. Petersen, K., et al., Systematic mapping studies in software engineering. 12th International Conference on Evaluation and Assessment in Software Engineering, 2008.
7. OASIS Standard, MQTT Version 5.0. 2019.
8. Satyanarayanan, M., The emergence of edge computing. *Computer*, 2017. 50(1): 30-39.
9. Shi, W., et al., Edge computing: Vision and challenges. *IEEE Internet of Things Journal*, 2016. 3(5): 637-646.
10. UNECE, Regulation No. 155 - Cyber security and cyber security management system. United Nations Economic Commission for Europe, 2021.
11. ISO, ISO/SAE 21434:2021 - Road vehicles: Cybersecurity engineering. International Organization for Standardization, 2021.
12. AlHousrya, O., et al., IoT-Enabled Driver Health Monitoring System Using Multi-Modal Sensors and Cloud Integration. *IEEE SIITME*, 2025.
13. Deng, Y., et al., Fuzzy Dijkstra algorithm for shortest path problem under uncertain environment. *Applied Soft Computing*, 2012. 12(3): 1231-1237.
14. Tajdin, A., et al., Computing a fuzzy shortest path in a network with mixed fuzzy arc lengths using alpha-cuts. *Computers & Mathematics with Applications*, 2010. 60(4): 989-1002.
15. Di Caprio, D., et al., A novel ant colony algorithm for solving shortest path problems with fuzzy arc weights. *Alexandria Engineering Journal*, 2022. 61(5): 3403-3415.

16. AlHousrya, O., et al., A novel Hybrid ant colony algorithm for solving the shortest path problems with mixed fuzzy arc weights. *Alexandria Engineering Journal*, 2024. 109: 841-855.
17. Lu, K., et al., Detecting driver fatigue using heart rate variability: A systematic review. *Accident Analysis & Prevention*, 2022. 178: 106830.
18. Liu, D., et al., OpenDriver: An open-road driver state detection benchmark. *Journal of Network and Computer Applications*, 2025. 242: 104279.
19. Meteier, Q., et al., A dataset on the physiological state and behavior of drivers in conditionally automated driving. *Data in Brief*, 2023. 47: 109027.
20. Alajlan, N.N., and Ibrahim, D.M., DDD TinyML: A TinyML-based driver drowsiness detection model using deep learning. *Sensors*, 2023. 23(12): 5696.
21. Abtahi, S., et al., YawDD: A yawning detection dataset. *Proceedings of the 5th ACM Multimedia Systems Conference*, 2014.
22. Guede-Fernandez, F., et al., Driver drowsiness detection based on respiratory signal analysis. *IEEE Access*, 2019. 7: 81826-81838.
23. Breiman, L., Random forests. *Machine Learning*, 2001. 45(1): 5-32.
24. Alzubaidi, L., et al., Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 2021. 8(1): 53.
25. AlHousrya, O., et al., A Hybrid Machine Learning and IoT System for Driver Fatigue Monitoring in Connected Electric Vehicles. *Machine Learning with Applications*, 2026: 100845.