UAB
Universitat Autònoma de Barcelona

Dipòsit digital de documents de la UAB

This is the **published version** of the bachelor thesis:

Avilés Pineda, Adriana. *Sistema de coaching intel·ligent per a la millora del rendiment en iRacing*. Treball de Final de Grau (Universitat Autònoma de Barcelona), 2026 (Grau en Enginyeria de Dades)

This version is available at https://ddd.uab.cat/record/337315

under the terms of the CC BY-SA license.

Sistema de coaching intel·ligent per a la millora del rendiment en iRacing

Adriana Avilés Pineda

Resum—L'evolució del *simracing* ha generat un volum massiu de dades de telemetria que les eines actuals només permeten visualitzar de forma bruta, sense diagnòstic accionable per a pilots amateurs. Aquest treball presenta un sistema de *coaching* intel·ligent per al simulador iRacing capaç de detectar ineficiències de conducció de manera autònoma. Utilitzant un Autoencoder LSTM entrenat exclusivament amb voltes expertes, el sistema avalua la telemetria de pilots amateurs mitjançant l'error de reconstrucció espacial per localitzar zones de millora al circuit. Finalment, una arquitectura híbrida tradueix l'anàlisi matemàtica en *feedback* en llenguatge natural amb models LLM, oferint recomanacions precises i directament accionables per a l'usuari.

Paraules clau—Deep Learning, Autoencoder, LSTM, telemetria, iRacing, simracing, coaching automatitzat, detecció d'anomalies, motorsport, LLMs, e-sports, circuit, GT3.

Abstract— The evolution of simracing has produced a massive volume of telemetry data that current tools only display in raw form, without actionable diagnosis for amateur drivers. This project presents an intelligent coaching system for the iRacing simulator, capable of autonomously detecting driving inefficiencies. Using an LSTM Autoencoder trained exclusively with expert laps, the system evaluates amateur telemetry through spatial reconstruction error to detect improvement zones on track. Finally, a hybrid architecture translates the mathematical analysis into natural language feedback using LLM models, providing precise and directly actionable recommendations for the user.

Index Terms—Deep Learning, Autoencoder, LSTM, telemetry, iRacing, simracing, automated coaching, anomaly detection, motorsport, LLMs, e-sports, track, GT3.

1 Introducció - Context del treball

El *simracing* (automobilisme virtual) ha experimentat un creixement exponencial durant l'última dècada, consolidant-se com a disciplina competitiva amb un ecosistema professional propi [1]. iRacing s'ha posicionat com la plataforma de referència gràcies a la seva fidelitat física i a la riquesa de les dades de telemetria que genera en temps real [3]. Cada volta produeix sèries temporals d'alta resolució amb canals com velocitat, frenada, acceleració, angle de volant, acceleracions laterals i longitudinals, RPM i velocitat de gir, entre d'altres.

No obstant això, existeix una bretxa significativa entre la disponibilitat d'aquestes dades i la capacitat dels pilots amateurs per interpretar-les. Les eines actuals, com Garage61 [4], es limiten a la visualització de gràfiques temporals sense oferir cap classe de diagnòstic automatitzat. Un pilot amateur pot observar que és més lent que un expert, però **no pot determinar on ni per què perd temps**.

Aquest treball neix per trencar aquesta barrera tècnica, proposant un **prototip funcional de sistema d'entrenament intel·ligent orientat a pilots amateurs d'iRacing**, capaç de detectar de forma autònoma anomalies i ineficiències en la tècnica de conducció fent ús de tècniques de *Deep Learning*. La hipòtesi central és que un Autoencoder LSTM entrenat exclusivament amb voltes d'experts aprèn una representació latent de la conducció òptima i, quan se li presenta una volta amateur, l'error de reconstrucció localitza automàticament les zones d'ineficiència. Un motor de feedback híbrid tradueix aquesta informació numèrica en consells naturals i accionables per al pilot.

Per assolir-lo, es plantegen els objectius específics següents: (1) construir un conjunt de dades de qualitat amb voltes de referència i de prova; (2) preprocessar i alinear les sèries temporals per a una comparació espacial coherent; (3) dissenyar i entrenar un model de *Deep Learning* que capturi els patrons de conducció experta; (4) implementar un sistema de detecció i classificació de desviacions significatives; i (5) desenvolupar una aplicació web interactiva per a la visualització i generació de *feedback*.

La resta del document s'organitza de la manera següent: la Secció 2 presenta l'estat de l'art, revisant els fonaments teòrics sobre l'anàlisi de telemetria, els models Autoencoder per a la detecció d'anomalies i l'ús de models de llenguatge (LLM) per a la generació de text. La Secció 3 detalla la metodologia tècnica, abastant des de l'adquisició i preprocessament de dades fins al disseny de l'arquitectura neuronal, l'optimització d'hiperparàmetres, la implementació del motor de *feedback* híbrid i l'aplicació

- *E-mail de contacte: 1676127@uab.cat*
- *Treball tutoritzat per: Ramón González Castillo (Arquitectura de computadors i sistemes operatius)*
- *Curs 2025/26*

web. A la Secció 4 s'exposen les mètriques d'avaluació i els resultats obtinguts, validant el sistema mitjançant un cas d'estudi real, i es clou amb la discussió sobre la viabilitat del projecte. Finalment, es presenten els agraïments, les referències bibliogràfiques i els apèndixs amb el material visual de suport.

2 ESTAT DE L'ART

Aquesta secció presenta una revisió dels fonaments teòrics i tecnològics que contextualitzen i fan possible el desenvolupament d'aquest projecte. Inicialment, s'analitza l'ús de la telemetria en el *simracing* i s'avaluen les limitacions de les plataformes actuals d'anàlisi de dades. Tot seguit, s'introdueixen els models Autoencoder LSTM com a eina per a la detecció d'anomalies, així com les tècniques d'optimització d'hiperparàmetres necessàries per al seu ajustament. A continuació, es descriu l'ús de Models de Llenguatge (LLM) per a la generació de recomanacions controlades en llenguatge natural. Finalment, la secció conclou identificant els reptes no resolts en l'estat de l'art i definint l'aportació d'aquest treball.

2.1 Telemetria en motorsport i simracing

La telemetria automobilística consisteix en l'adquisició remota de dades dinàmiques del vehicle en temps real. En el *motorsport* professional, equips d'enginyeria analitzen centenars de canals per optimitzar la configuració del vehicle i la tècnica del pilot. En el *simracing*, plataformes com iRacing exposen canals equivalents (velocitat, inputs del pilot, dinàmica del vehicle, etc.) a través de fitxers de dades estructurats. Eines com Garage61 [4,5] permeten descarregar i visualitzar la telemetria de qualsevol pilot registrat, però no ofereixen diagnòstic automatitzat ni recomanacions de millora.

D'altra banda, l'auge del *simracing* ha impulsat l'aparició de plataformes comercials com Trophi.ai, que ofereixen anàlisi de telemetria per a iRacing. Tot i aquest avenç, aquestes solucions acostumen a operar com a models de "caixa negra", no fan explícita la lògica interna de detecció d'errors ni els criteris que sustenten les recomanacions, i a més, requereixen subscripcions de pagament. Aquest buit entre eines de dades crues gratuïtes i plataformes de *coaching* tancades, crea la necessitat de sistemes oberts, transparents i interpretables, basats en el diagnòstic directe de l'error de reconstrucció.

2.2 Autoencoders per a detecció d'anomalies

Els Autoencoders són xarxes neuronals que aprenen a comprimir una entrada en un espai latent de menor dimensionalitat i a reconstruir-la [17]. Quan s'entrenen exclusivament amb dades d'una classe (conducció experta), l'error de reconstrucció actua com a puntuació d'anomalia: les mostres fora de la distribució apresa generen un error significativament superior. La variant LSTM (Long Short-Term Memory) [7] és especialment adequada per a sèries temporals, ja que incorpora mecanismes que capturen dependències temporals llargues de forma nativa. Això és crític en telemetria, on una frenada tardana afecta la dinàmica del vehicle durant centenars de metres posteriors.

2.3. Optimització d'hiperparàmetres

L'optimització bayesiana, implementada per biblioteques com Optuna [11], utilitza l'algorisme TPE (*Tree-structured Parzen Estimator*) per explorar l'espai d'hiperparàmetres de forma eficient, dirigint la cerca cap a regions prometedores [9, 10]. Aquesta tècnica és particularment rellevant en contextos amb *datasets* petits, on la configuració d'hiperparàmetres té un impacte crític en la capacitat de generalització.

2.4. Models de llenguatge per a generació de feedback

Els models de llenguatge de gran escala (LLM) han demostrat la capacitat per generar text coherent i contextualitzat a partir d'informació estructurada [13, 18]. La seva integració en sistemes d'anàlisi de dades permet traduir resultats numèrics en explicacions naturals comprensibles per a usuaris no tècnics. No obstant això, el risc d'al·lucinació requereix estratègies de control com la restricció del *prompt* i l'ús de temperatures baixes, un hiperparàmetre que controla l'aleatorietat de les prediccions del model. Una temperatura propera a zero força el model a seleccionar exclusivament els *tokens* més probables, afavorint respostes altament deterministes i predictibles. Aquesta parametrització és fonamental en dominis crítics com la telemetria, ja que assegura que el text generat s'adhereixi estrictament a les dades estadístiques proporcionades a l'entrada, evitant la invenció de recomanacions de conducció físicament incorrectes o perilloses [19].

2.5. Reptes actuals i aportació d'aquest projecte

La revisió de l'estat de l'art evidencia que, tot i disposar de telemetria d'altra resolució i de models capaços de processar-la, no existeix una solució integral de codi obert que automatitzi completament el cicle de diagnòstic per a iRacing. Els dos reptes principals són, d'una banda, transformar l'error d'un model neuronal en informació interpretable per al pilot (què falla, on falla i amb quin impacte), i de l'altra, controlar la fiabilitat del llenguatge generat per LLM, evitant al·lucinacions i mantenint traçabilitat entre dada, diagnòstic i consell final.

En aquest context, l'aportació central d'aquest projecte és el disseny d'una arquitectura neuronal híbrida. En lloc d'utilitzar l'aprenentatge automàtic només per fer prediccions de temps, es fa servir l'Autoencoder LSMT optimitzat per extreure matemàticament la ineficiència espacial. Sobre aquesta sortida, un motor de regles determinista actua com a capa de validació i control abans de la generació en llenguatge natural. Això garanteix que el *feedback* final en llenguatge natural sigui sempre segur, coherent i basat estrictament en la física de conducció, superant així l'opacitat de les eines comercials actuals.

3 METODOLOGIA

La metodologia tècnica emprada per al desenvolupament del sistema aborda des de l'adquisició, exploració i preprocessament de dades de telemetria per a la construcció del conjunt de dades, passant pel disseny i entrenament del model d'aprenentatge profund, fins a arribar a la implementació del motor de *feedback* híbrid i el desenvolupament d'una aplicació web interactiva que integra tot el *pipeline*.

3.1. Font de dades i exploració

Les dades s'han extret de la plataforma Garage61 [4, 5] de forma automatitzada, acotant l'estudi al vehicle Ferrari 296 GT3 al circuit d'Autodromo Internazionale Enzo e Dino Ferrari (Imola). S'han obtingut un total de 845 voltes de pilots únics, cadascuna amb la sèrie temporal completa dels canals de telemetria i les metadades ambientals i de configuració (temperatura de pista, temperatura de l'aire, humitat, velocitat del vent, precipitació, compost dels pneumàtics i nivell de combustible).

L'exploració inicial ha revelat una distribució dels temps per volta (vegeu la Figura A.1 a l'Apèndix) concentrada en el rang de 101.5s a 103s. El percentil 25 (P25 = 101.468s) s'ha utilitzat com a llindar per aïllar les voltes d'expert, mentre que el percentil 75 marca el nivell amateur. A més, la comparació dels canals de telemetria entre ambdós grups, experts i amateurs, ha evidenciat diferències significatives en la variància dels canals de fre i accelerador, on els amateurs presenten oscil·lacions que el model haurà de detectar com a anomalies (vegeu la Figura A.2 a l'Apèndix).

L'anàlisi de correlació ha confirmat que la temperatura de pista (r = 0.31) i la temperatura de l'aire (r = 0.20) presenten la associació positiva més alta amb el temps de volta, justificant el filtratge per condicions ambientals (vegeu la Figura A.3 a l'Apèndix).

3.2. Construcció del dataset

El *pipeline* de construcció del dataset segueix una rigorosa neteja.

1. **Interpolació uniforme:** remostreig de cada volta sobre una graella de 1000 punts equidistants en percentatge de distància de volta (*LapDistPct*), eliminant la dependència de la densitat de mostra original i homogeneïtzant la longitud de totes les seqüències.
2. **Filtre ambiental:** eliminació de voltes amb precipitació, pista mullada o pneumàtics de pluja, conservant únicament condicions de pista seca i pneumàtic sec *(tyre_compund = 1)*.
3. **Filtre d'integritat:** eliminació de voltes amb valors NaN a la matriu interpolada.
4. **Filtre d'outliers:** descart de voltes amb temps superior a 130s, son temps extremadament inusuals que podria dur-se a incidents o tornada a *pit lane*.
5. **Divisió per nivell**: classificació en expert (percentil ≤ 25) o amateur (percentil ≥ 75).
6. **Filtre de combustible**: finestra de 10-60L per a l'entrenament, reduint la variabilitat no associada al pilotatge (vegeu la Figura A.4 a l'Apèndix).

El resultat és un conjunt de 149 voltes d'expert (rang 1:39.611–1:41.386) per a l'entrenament i 178 voltes amateur (rang 1:42:444 – 1:42:839) per al test. Les sortides son arrays NumPy de forma *(n_voltes, 1000, n_canals)*.

Els **9 canals de telemetria** seleccionats són: *Speed, Throttle, Brake, RPM, SteeringWheelAngle, Gear, LatAccel, LongAccel i YawRate*. Durant la fase d'enginyeria de característiques (*Feature Engineering*), es van excloure les coordenades geogràfiques (*Lat, Lon*) de la matriu d'entrenament, ja que no aporten informació sobre la tècnica de conducció i només es conserven per a la visualització posterior. Addicionalment, es va prendre la decisió d'eliminar l'acceleració vertical (*VertAccel*). Aquest canal introduïa un alt grau de soroll ambiental al sistema, ja que captura principalment les irregularitats de l'asfalt i l'impacte amb els pianos, en lloc de reflectir les accions directes del pilot. L'eliminació d'aquest canal va millorar dràsticament la sensibilitat de l'Autoencoder, incrementant el *recall* de detecció d'anomalies de 0.62 al 0.83.

Abans de l'entrenament, s'aplica una estandardització *z-score* per canal sobre el conjunt de *train*. Per a cada canal, es calcula la mitjana i la desviació estàndard a partir de totes les mostres d'entrenament aplanades, i es transforma cada valor. Aquesta transformació és fonamental perquè els 9 canals de telemetria operen en escales molt diferents. Sense normalització, la funció de pèrdua MSE (*Mean Squared Error*), quedaria dominada pels canals de major magnitud i el model ignoraria els altres canals. Els paràmetres es calculen únicament sobre les dades d'entrenament per evitar *data leakage*.

3.3. Arquitectura del model

El model escollit és un **Autoencoder LSTM seqüència a seqüència** (*seq2seq*). El LSTM permet capturar de forma nativa les dependències seqüencials llargues de la telemetria (una frenada executada massa tard afecta la dinàmica del vehicle durant els punts posteriors dins de la corba). Gràcies a la seva memòria temporal el fa molt eficient amb conjunts petits.

L'Autoencoder aprèn la distribució experta sense requerir etiquetes d'error (aprenentatge no supervisat), l'error de reconstrucció localitza automàticament les anomalies.

Finalment, la mida del *dataset* és un factor determinant en l'elecció d'aquesta arquitectura, ja que, amb 149 exemples d'entrenament, cal una arquitectura petita i amb biaixos per evitar sobreajustament. El LSTM és la millor opció enfront dels Transformers (necessiten molts exemples per aprendre l'atenció) o CNN 1D (no capturen bé les dependències llargues) [7].

3.4. Optimització d'hiperparàmetres

L'arquitectura inicial (128 unitats, 1 capa LSTM, espai latent de 32) presentava una variància elevada en la validació creuada 5-Fold (MSE = 0.2413 ± 0.0435). Per estabilitzar el rendiment, s'ha aplicat una optimització bayesiana amb Optuna (50 trials amb TPE, validació creuada de 2 folds, *MedianPruner* per interrompre trials inferiors).

La Taula 1 compara els hiperparàmetres manuals amb els optimitzats.

Taula 1: Evolució dels hiperparàmetres després d'aplicar optimització bayesiana.

Hiperparàmetre	Manual (Informe I)	Optuna (Informe II)
Learning Rate	1e-3	4.57e-4
Weight decay	1e-4	3.49e-5
Dropout	0.2	0.331
Hidden size	128	256
Latent dim	32	32
N layers	1	2
Batch size	6	8
Noise std	0.01	0.033
N augments	9	8

Optuna ha seleccionat un model de capacitat superior (256 unitats, 2 capes) amb regularització més agressiva (dropout de 0.33), indicant que l'arquitectura original estava infradimensionada. El *learning rate* s'ha reduït a la meitat (4.57e-4), indicant que la xarxa més profunda necessita una convergència més suau per evitar oscil·lacions. La dimensió latent s'ha mantingut en 32, confirmant-la com l'espai òptim per codificar la variabilitat dels canals.

3.5. Entrenament final

L'entrenament s'ha realitzat sobre el conjunt complet de 149 voltes d'expert (85% entrenament, 15% validació) amb augmentació de dades mitjançant soroll gaussià (σ = 0.033, 8 còpies per volta), elevant el conjunt efectiu a 1341 mostres. La configuració d'entrenament inclou:

- **Optimitzador**: Adam (lr = 4.57e-4, weight decay = 3.49e-5) [8].
- **Scheduler**: ReduceLROnPlateau (factor 0.5, paciència 25 èpoques)
- **Gradient clipping**: prevenció de l'exposició de gradients (max_norm = 1).
- **Early stopping**: atura l'entrenament si no hi ha millora en la *loss* de validació durant 50 èpoques consecutives.
- **Funció de pèrdua**: MSE (*Mean Squared Error*), que mesura la diferència quadràtica mitjana entre la seqüència original i la reconstruïda.
- **Èpoques**: 300

L'evolució de la funció de pèrdua (vegeu la Figura A.5 a l'Apèndix) mostra una convergència robusta amb una pèrdua de validació final de 0.1106. Els pics puntuals observats durant l'entrenament s'atribueixen a l'ajust dels gradients amb un *batch size* reduït, però l'estabilitat final indica que el model ha après els patrons sense indicis de *overfitting*.

3.6. Motor de feedback

El motor de *feedback* implementa una arquitectura de tres capes per traduir l'error de reconstrucció en recomanacions accionables:

Capa 1 – Anàlisi estadístic

Aquesta capa és l'anàlisi determinista que sempre s'executa, independentment de la disponibilitat de serveis externs. Inclou les funcionalitats següents:

- **Càlcul de l'error amb signe:** es computa la diferència signada entre la reconstrucció experta i la telemetria amateur real (error signat = reconstrucció experta – telemetria amateur). El signe positiu indica que l'amateur queda per sota del patró expert (ex. velocitat inferior) i el signe negatiu indica que el supera (ex. frenada excessiva).
- **Detecció de zones de *coaching*:** s'identifiquen les regions del circuit on l'error de reconstrucció suavitzat supera el percentil 75, filtrant zones inferiors al 0.5% de la volta. Es retornen les 5 zones principals ordenades per severitat.
- **Anàlisi per canal:** dins de cada zona, es descompon l'error per canal, es converteix a unitats físiques (km/h, %, rpm, °, g, °/s) i s'ordena per severitat, generant objectes *ChannelDeviation* amb la direcció de la desviació (*over/under*).
- **Detecció de cadenes causals:** s'implementen 5 patrons causals coneguts en *motorsport*:
  1. **Frenada tardana/feble → velocitat excessiva a l'àpex → subviratge:** una frenada tardana o amb pressió insuficient provoca una velocitat excessiva en arribar al punt d'àpex. Aquesta inèrcia supera el límit d'adherència de l'eix davanter, generant un fenomen de subviratge.
  2. **Acceleració agressiva → inestabilitat de gir → correcció de volant:** l'aplicació agressiva del gas durant la traçada indueix un moment de gir (o inestabilitat en l'eix vertical) que obliga al pilot a realitzar una correcció ràpida del volant per mantenir el control del vehicle.
  3. **Frenada prematura → velocitat baixa a l'àpex → acceleració compensatòria:** una reducció de velocitat massa primerenca deriva en un pas per l'àpex excessivament lent. Com a conseqüència, el pilot es veu obligat a realitzar una acceleració compensatòria abans del previst per recuperar el temps perdut.
  4. **Volant excessiu → pèrdua de velocitat → sortida deficient:** un angle de volant excessiu augmenta la fricció i el fregament dels pneumàtics, la qual cosa provoca una pèrdua de velocitat cinètica i, finalment, una sortida de revolt deficient per falta de tracció.

5. **Acceleració tardana → mala sortida de corba:** el retard en l'obertura del gas respecte al punt òptim de tracció penalitza directament la velocitat de sortida, comprometent el rendiment del vehicle en el següent sector recte.

Cada cadena causal es valida mitjançant anàlisi de correlació temporal amb retard i s'acompanya d'una puntuació de confiança entre 0 i 1.

- **Estimació de la pèrdua de temps:** aproximació basada en la fracció de volta de la zona, el temps de volta i la diferència de velocitat respecte a la referència experta.

Capa 2 – Plantilla de feedback

Genera text estructurat a partir de plantilles parametritzades amb els valors numèrics concrets de l'anàlisi estadística. Cada combinació (canal, direcció) disposa d'un missatge prescrit, per exemple, *(Brake, under)* → "*Estàs frenant massa tard o amb pressió insuficient*" i cada combinació causal disposa d'un consell associat. Serveix com a cas de fallada si la capa 3 no està disponible.

Capa 3 – Coaching per LLM

Transforma l'anàlisi estructurada (JSON) en text de *coaching* natural mitjançant un LLM (Groq per defecte, Gemini com a alternatiu). El *prompt* inclou les dades estadístiques completes de la zona amb la instrucció explícita que **el LLM no ha d'inventar dades sinó utilitzar exclusivament els valors numèrics proporcionats.** S'empra una temperatura de 0.3 amb instruccions explícites per evitar al·lucinacions. En cas d'error, reverteix a la capa 2.

3.7. Aplicació Web

S'ha desenvolupat una interfície web interactiva amb Streamlit que implementa el *pipeline* complet en tres fases progressives: (1) càrrega i interpolació del CSV, (2) inferència de l'Autoencoder i detecció de zones, i (3) generació de *feedback* LLM en segon pla. L'aplicació inclou visualització del mapa del circuit amb zones codificades pel color, superposició de telemetria expert/amateur, targetes de *coaching* amb severitat i recomanacions generades pel LLM. El prototip funcional d'aquesta aplicació es troba desplegat i lliurement accessible [21].

4. AVALUACIÓ, RESULTATS I DISCUSSIÓ

L'avaluació del model s'ha estructurat en quatre dimensions complementàries: l'error de reconstrucció global, la capacitat de discriminació per canal, la classificació binària expert/amateur i la correlació amb el temps de volta. Addicionalment, s'ha validat el sistema complet amb un cas d'estudi real.

4.1. Error de reconstrucció

L'error de reconstrucció s'ha calculat sobre les 327 voltes del *dataset* (149 experts + 178 amateurs) en l'espai normalitzat, emprant tres mètriques complementàries: MSE (penalitza valors atípics), MAE (desviació mitjana sense penalització quadràtica) i RMSE (manté l'escala original), tal com es resumeix a la Taula 2.

Taula 2: Comparativa de l'error de reconstrucció entre els dos grups.

Grup	MSE (mean + std)	RMSE	MAE	Número voltes
Expert (train)	0.1048 ± 0.0207	0.3237	0.1702	149
Amateur (test)	0.1382 ± 0.0297	0.3717	0.1949	178

Com s'observa a les dades anteriors, l'increment del 31.9 % en la MSE mitjana dels amateurs confirma que el model assigna un error significativament superior a les voltes fora de la distribució experta. L'error amateur és superior de forma proporcional en les tres mètriques, indicant una ineficiència sistemàtica i no puntual.

4.2. Anàlisi per canal

La descomposició de l'error per canal (Taula 3) quantifica la capacitat discriminant de cadascuna de les variables d'entrada del model. Com s'hi pot observar, existeix una clara jerarquia en les ineficiències de conducció.

D'una banda, el fre (ràtio 1.53) i la velocitat (ràtio 1.48) són els canals amb poder discriminant més elevat. Aquest resultat és coherent amb el coneixement teòric del *motorsport*: la gestió de la frenada és l'habilitat de major dificultat tècnica [12].

Per contra, els canals relacionats directament amb la inèrcia del cotxe, com l'acceleració lateral (ràtio 1.10) i velocitat de gir (ràtio 1.07) mostren menor discriminació. Això suggereix que el comportament lateral del cotxe ve determinat principalment per la física del vehicle i no tant per la tècnica específica del pilot.

Taula 3: Error de reconstrucció per canal.

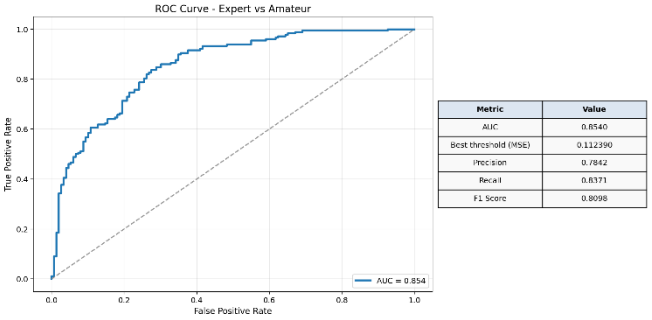
Canal	MSE Expert	MSE Amateur	Ràtio
Brake	0.0933	0.1425	1.53
Speed	0.0065	0.0096	1.48
RPM	0.3153	0.4441	1.41
SteeringWheelAngle	0.0814	0.1134	1.39
LongAccel	0.0703	0.0972	1.38
Gear	0.1474	0.1822	1.24
Throttle	0.0758	0.0886	1.17
LatAccel	0.0688	0.0755	1.10
YawRate	0.0840	0.0902	1.07

4.3. Classificació binària

Per quantificar la capacitat discriminativa del model, s'ha tractat el MSE per volta com a puntuació d'anomalia en un problema de classificació binària (expert = 0, amateur

= 1). El llindar òptim s'ha determinat mitjançant l'estadístic J de Youden sobre la corba ROC.
L'Àrea Sota la Corba (AUC) obtinguda és de 0.854 (Figura 1), la qual cosa indica una alta probabilitat que el model assigni un error de reconstrucció superior a una volta amateur que a una experta, demostrant una excel·lent separabilitat entre classes malgrat no utilitzar etiquetes durant l'entrenament.

L'elecció del llindar de Youden maximitza l'equilibri entre falsos positius i falsos negatius, donant com a resultat un F1-Score de 0.809. En el context d'un sistema de *coaching*, aquesta mètrica global és crítica, ja que indica que el sistema aconsegueix de forma sòlida identificar la majoria de les ineficiències.



Metric	Value
AUC	0.8540
Best threshold (MSE)	0.112390
Precision	0.7842
Recall	0.8371
F1 Score	0.8098

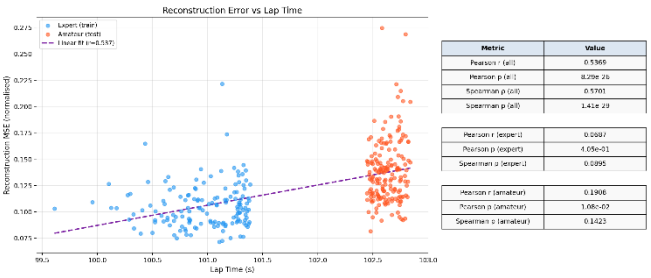
Figura 1: Corba ROC amb taula de mètriques.

Considerant que la diferència entre grups és d'aproximadament 1.5s sobre un temps total de ~102s, la separació és intrínsecament difícil. Tot i això, el model aconsegueix identificar el 83.7% (*recall*) de les voltes amateurs. Les 29 voltes amateurs classificades errròniament com a expertes (falsos negatius) corresponen als pilots més propers al llindar de separació. Al mateix temps, s'assoleix una precisió de 0.784, assegurant l'alta fiabilitat de les recomanacions en minimitzar els falsos positius, una qualitat indispensable per no frustrar a l'usuari amb indicacions d'error infundades.

4.4. Correlació MSE – Temps de volta

Per verificar que l'error de reconstrucció del model reflecteix el rendiment real del pilot, s'ha calculat la correlació entre el MSE per volta i el temps de volta (Figura 2). S'han aplicat dues mesures de correlació: Pearson (correlació lineal) i Spearman (correlació monòtona basada en rangs).

La correlació de Spearman entre la MSE per volta i el temps de volta és de $\rho = 0.570$, confirmant una associació positiva: a major temps de volta, major error de reconstrucció [14,15]. S'ha emprat Spearman com a mètrica principal perquè no assumeix normalitat ni linealitat, sent més robusta davant *outliers* i distribucions no gaussianes.



Metric	Value
Pearson r (all)	0.5369
Pearson p (all)	8.29e-26
Spearman ρ (all)	0.5701
Spearman p (all)	1.41e-29
Pearson r (expert)	0.0887
Pearson p (expert)	4.05e-01
Spearman ρ (expert)	0.0895
Pearson r (amateur)	0.1906
Pearson p (amateur)	1.08e-02
Spearman ρ (amateur)	0.1423

Figura 2: Dispersió del MSE per volta respecte al temps de volta, amb línia de regressió.

4.5. Cas d'estudi – Pilot amateur (Dani Gracia)

Per validar el sistema complet, s'han analitzat 3 voltes d'un pilot amateur real al circuit d'Imola (Taula 4). Per a cada volta, el *pipeline* calcula: (1) la MSE normalitzada de reconstrucció, (2) la ràtio respecte a la MSE mitjana experta i (3) la pèrdua de temps estimada.

La Taula 4 mostra una clara evolució d'aprenentatge. L'experiment es va dissenyar perquè el pilot analitzés la seva telemetria amb el prototip després de cada intent. A mesura que el pilot va aplicar les correccions suggerides pel motor de *feedback*, la reducció del temps de volta (1:44:845 → 1:42:797) va anar acompanyada d'una caiguda dràstica de l'error de reconstrucció (0.2711 → 0.2003). Això demostra l'impacte directe i positiu del sistema en la correcció de la tècnica del pilot. S'observa, com la volta més ràpida presenta la MSE més baixa, mentre que la volta més lenta presenta la més alta. Aquesta relació és consistent amb la hipòtesi del model: a major desviació respecte al patró expert, pitjor rendiment global de volta.

Taula 4: Resultats del pilot amateur Dani Gracia.

Volta	Temps	MSE (normalitzat)	Ràtio vs Expert	Temps perdut estimat
1	1:44.845	0.2711	1.54x	1.557s
2	1:43.402	0.2559	1.45x	1.236s
3	1:42.797	0.2003	1.14x	0.771s

Per a la volta 3 (Figura 3), el motor estadístic identifica 5 zones de *coaching* amb un temps perdut estimat de 0.549s. En concret, a la zona 4 es detecta un excés de velocitat de +1.3 km/h respecte al patró expert, associat a una frenada insuficient, que deriva en subviratge. A la zona 1, l'acceleració tardana resulta en 750 RPM (Revolucions per Minut) per sota del nivell expert, comprometent la sortida de corba.

És important remarcar que aquests valors (ex. +1.3 km/h, -750 RPM, pèrdua de temps per zona) provenen directament de la sortida numèrica del motor d'anàlisi estadístic, el LLM no els estima ni els inventa, sinó que transforma en text natural. Això garanteix la coherència entre el consell generat i l'anàlisi numèrica.

A continuació es mostra l'extracte literal generat pel motor de *feedback* (Capa 3) per a la zona 4, on s'observa com s'incorporen els valors exactes sense patir al·lucinació:

"You're carrying 1.3 km/h more speed than the expert through this segment, which is likely due to insufficient braking. Try braking 0.2% harder to match the expert's brake input, and aim to be closer to the expert's RPM — you're currently 459.4 rpm below the expert's level."

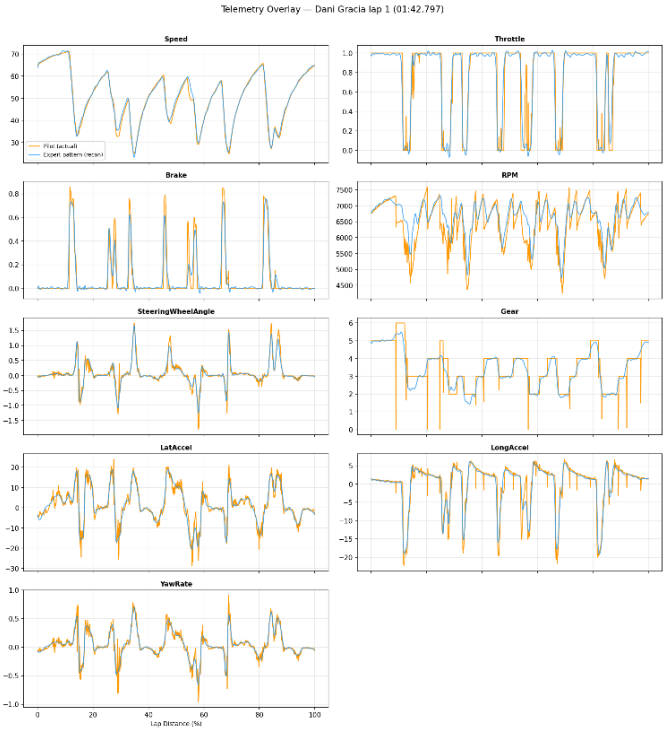


Figura 3: Superposició de telemetria de la volta 3 de Dani Gracia amb un temps de 1:42:797.

4.6. Discussió

Els resultats obtinguts confirmen la viabilitat de l'enfocament proposat. L'increment del 31.9% en el MSE dels pilots amateurs, la consistència de la discriminació en les tres mètriques d'error (MSE, RMSE, MAE) i un AUC de 0.854 demostren que el model Autoencoder LSTM captura patrons reals de la conducció experta. El fet que l'error amateur sigui proporcionalment superior en totes les mètriques indica una ineficiència generalitzada al llarg de la volta, no anomalies puntuals o causades per soroll. Això és un indicador positiu de robustesa del model.

L'anàlisi per canal revela una coherència notable amb el coneixement del *motorsport*: la frenada (ràtio 1.53) i velocitat (ràtio 1.48) són precisament els aspectes que els enginyers de pista identifiquen com a determinants del rendiment. Per contra, l'acceleració lateral (ràtio 1.10) i la velocitat de gir (ràtio 1.07) mostren menor capacitat discriminativa, suggerint que el comportament lateral ve determinat principalment per la física del vehicle.

Finalment, la validació amb el cas d'estudi del pilot Dani Gracia és especialment reveladora. Les tres voltes mostren una progressió lògica: a mesura que millora el temps de volta (1:44:845 → 1:42:797), disminueix el MSE (0.2771 → 0.2003). Això indica que el sistema permet fer un seguiment clar de l'evolució i l'aprenentatge del pilot. A més, el *feedback* generat pel LLM, que incorpora valors exactes, demostra que la capa híbrida és capaç de transformar l'anàlisi en consells concrets i accionables sense caure en al·lucinacions.

5. Conclusions

El present treball ha abordat amb èxit la problemàtica de la interpretació de la telemetria en el *simracing*, desenvolupant un sistema de *coaching* intel·ligent *end-to-end* capaç de traduir dades brutes en recomanacions accionables per a pilots amateurs. A partir del disseny, implementació i avaluació del prototip, s'extreuen les conclusions fonamentals següents:

1. **Viabilitat i eficàcia de l'aprenentatge no supervisat:** s'ha demostrat que una arquitectura neuronal basada en Autoencoders LSTM és altament capaç d'aprendre la representació latent d'una conducció experta òptima sense necessitat d'etiquetatge previ. El model ha aconseguit discriminar les ineficiències de la conducció amateur de manera localitzada, assolint una capacitat de separabilitat excel·lent (AUC de 0.854 i un F1-Score de 0.810). Alhora, l'optimització bayesiana d'hiperparàmetres mitjançant Optuna ha estat determinant per estabilitzar el model i evitar el sobreajustament, confirmant que una arquitectura de 256 unitats i un espai latent de 32 dimensions ofereixen l'equilibri idoni entre compressió d'informació i generalització.
2. **Rellevància del Feature Engineering i validació física del model:** l'anàlisi de l'error per canal ha posat de manifest que el model no es basa en l'aleatorietat matemàtica, sinó que ha assolit una comprensió real de les dinàmiques del vehicle. La identificació de la gestió del fre (ràtio 1.53) i de la velocitat (ràtio 1.48) com els canals més discriminants concorda plenament amb la teoria del *motorsport*. A més, la decisió d'excloure l'acceleració vertical (*VertAccel*) ha subratllat la importància del filtratge de soroll ambiental, una acció que va millorar dràsticament el *recall* del sistema (0.62 → 0.83).
3. **Correlació directa amb el rendiment del circuit:** l'estudi de la correlació de Spearman (ρ = 0.570) ha validat matemàticament la hipòtesi que l'error de reconstrucció del model es tradueix en una pèrdua de temps al cronòmetre. Aquesta troballa certifica que les anomalies detectades no són meres variacions d'estil de conducció, sinó ineficiències tècniques reals que penalitzen el rendiment del pilot amateur.
4. **Viabilitat de l'arquitectura neuro-simbòlica per a la generació de feedback:** l'aportació més innovadora ha estat la integració d'una arquitectura híbrida. La combinació d'un model neuronal, un motor determinista de regles causals i un LLM produeix un sistema que és alhora potent, interpretable i segur. Tot i el risc d'al·lucinació dels models de llenguatge gran (LLM) quan es tracten

amb dades físiques, el disseny d'un motor estadístic determinista que actua com a pas intermedi garanteix la traçabilitat del diagnòstic. L'ús del LLM amb una configuració de temperatura baixa ha permès transformar dades numèriques exactes i cadenes causals en explicacions naturals i fiables. Demostrant que es possible oferir un *coaching* personalitzat, transparent i segur, superant l'opacitat de les solucions comercials de "caixa negra".

5.1. Limitacions i línies de treball futur

Tot i l'assoliment dels objectius proposats, el sistema presenta certes limitacions que obren camí a futures investigacions i desenvolupaments.

- **Dependència del volum de dades:** la variància observada durant l'entrenament K-Fold indica que el model continua sent sensible a la mida del conjunt de dades expertes. Una ingesta més gran de dades amb noves voltes de referència estabilitzaria encara més els gradients i augmentaria la resolució per detectar ineficiències subtils.
- **Escalabilitat a altres circuits i vehicles:** el prototip actual s'ha acotat al vehicle Ferrari 296 GT3 al circuit d'Imola. Com a treball futur, caldria ampliar l'entrenament del model perquè sigui capaç d'adaptar-se als diferents circuits o vehicles.
- **Extensió a altres simuladors:** adaptar l'enfocament a altres simuladors amb estructura de telemetria similar.
- **Integració en temps real:** adaptar el *pipeline* per integrar el sistema en temps real, cosa que permetria que el pilot rebi el *feedback* de forma immediata durant la sessió, mentre condueix.

5.2. Reflexió final

El *simracing* s'ha consolidat com a plataforma legítima per a l'entrenament de pilots professionals i amateurs. La disponibilitat de telemetria d'alta qualitat representa una oportunitat única per industrialitzar el *feedback* de pilotatge. Però fins avui, aquesta oportunitat s'ha aprofitat parcialment: les dades estaven accessibles, però no interpretades de manera sistemàtica. Aquest treball ha intentat tancar aquesta bretxa proporcionant una solució transparent, interpretable i accionable. No pretén reemplaçar l'experiència d'un enginyer humà, sinó complementar-la, oferint una anàlisi 24/7 disponible per a qualsevol pilot amb connexió a internet.

AGRAÏMENTS

Vull expressar el meu agraïment al meu tutor, Ramón González, per la seva orientació i suport constant durant el desenvolupament d'aquest projecte.

Sobretot, vull fer una menció especial i agrair enormement al pilot Dani Gracia per la seva implicació com a cas d'estudi. La seva predisposició per posar a prova el sistema i proporcionar la seva telemetria ha estat una peça fonamental per validar el projecte al món real. Gràcies per la confiança i per fer possible l'aplicació pràctica d'aquesta eina.

Finalment, agraeixo a la comunitat d'iRacing i a la plataforma de Garage61 per fer accessibles les dades de telemetria de milers de pilots que han permès construir els fonaments d'aquest sistema de *coaching*.

DECLARACIÓ D'ÚS D'INTEL·LIGÈNCIA ARTIFICIAL

Durant el desenvolupament d'aquest projecte, s'ha emprat l'assistent d'intel·ligència artificial Claude com a eina de suport exclusivament per al *debugging* de codi, l'optimització de funcions en Python i del *front-end* en Streamlit.

BIBLIOGRAFIA

[1] Simdraft, "Evolución de los eSports de Simracing" Simdraft Magazine. [Online]. Disponible a: http://www.simdraft.com/noticias/evolucion-de-los-esports-de-simracing/

[2] Simufy Academy, "Plataforma de coaching i entrenament virtual" Simufy. [Online]. Disponible a: https://academy.simufy.com/

[3] iRacing, "iRacing vs The Real Thing: The Ultimate Simulation" iRacing.com. [Online]. Disponible a: https://www.iracing.com/iracing-vs-the-real-thing/

[4] Garage61, "Garage61 Telemetry App and Platform" Garage61.net. [Online]. Disponible a: https://garage61.net/app

[5] Garage61, "Garage61 API", pypi.org. [Online]. Disponible a: https://pypi.org/project/garage61api/

[6] SciPy Developers, "scipy.interpolate.interp1d — SciPy Manual" SciPy.org. [Online]. Disponible a: https://docs.scipy.org/doc/scipy/reference/generated/scipy.interpolate.interp1d.html

[7] T. Balarabe, "Long Short-Term Memory (LSTM) Networks: Solving the Problem of Memory" Medium, [Online]. Disponible a: https://medium.com/@tahirbalarabe2/long-short-term-memory-lstm-networks-solving-the-problem-of-memory-f3c691bd5b39

[8] D. P. Kingma i J. Ba, "Adam: A method for stochastic optimization" arXiv preprint arXiv:1412.6980, 2014. [Online]. Disponible a: https://arxiv.org/abs/1412.6980

[9] GeeksforGeeks, "Hyperparameters Optimization Methods in ML," GeeksforGeeks. [Online]. Disponible a: https://www.geeksforgeeks.org/machine-learning/hyperparameters-optimization-methods-ml/

[10] L. Franceschi et al., "Hyperparameter Optimization in Machine Learning," arXiv preprint arXiv:2410.22854, 2024. [Online]. Disponible a: https://arxiv.org/html/2410.22854v3#Ch4.S2

[11] Optuna Developers, "Optuna: A hyperparameter optimization framework," Optuna.org. [Online]. Disponible a: https://optuna.org/

[12] Suspension Secrets, "Lateral and Longitudinal Load Transfer," Suspension Secrets. [Online]. Disponible a: https://suspensionsecrets.co.uk/lateral-and-longitudinal-load-transfer/

[13] AI Tools SME, "Comparison of Language Models," AI Tools SME. [Online]. Disponible a: https://www.aitoolssme.com/comparison/language-models
[14] TurinTech AI, "Four Methods to Statistically Measure Your Data Correlation," TurinTech AI Blog, 2022. [Online]. Disponible a: https://www.turintech.ai/blog/four-methods-to-statistically-measure-your-data-correlation
[15] P. Schober, C. Boer i L. A. Schwarte, "Correlation Coefficients: Appropriate Use and Interpretation," Anesthesia & Analgesia, vol. 126, núm. 5, pp. 1763-1768, 2018. [Online]. Disponible a: https://journals.lww.com/anesthesia-analgesia/fulltext/2018/05000/correlation_coefficients__appropriate_use_and.50.aspx
[16] Anthropic. (2026). Claude Opus 4.6. (Model de llenguatge de IA). https://www.claude.com
[17] IBM, "What is an Autoencoder?," IBM Think. [Online]. Disponible a: https://www.ibm.com/think/topics/autoencoder
[18] IBM, "What are Large Language Models?," IBM Think. [Online]. Disponible a: https://www.ibm.com/es-es/think/topics/large-language-models
[19] K. Wang, "A Comprehensive Guide to LLM Temperature," Medium, 2025. [Online]. Disponible a: https://medium.com/@kelseyywang/a-comprehensive-guide-to-llm-temperature-%EF%B8%8F-363a40bbc91f
[20] Sim Racing Coaching, AI Coach for Sim Racing by trophi.ai. [Online]. Disponible a: https://www.trophi.ai/sim-racing-coaching/iracing
[21] A. Avilés Pineda, "AI Coaching for iRacing – Web Prototype", 2026. [Online]. Disponible a: https://ai-coaching-for-iracing.streamlit.app/

APÈNDIX

A. FIGURES DE SUPORT METODOLÒGIC I DE RESULTATS

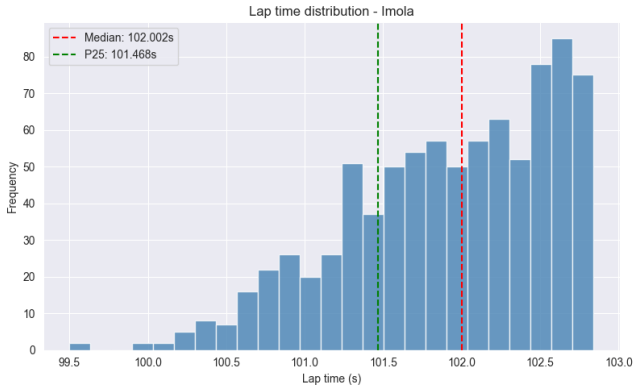


Figura A.1: Distribució del temps per volta del conjunt complet. Aquesta figura justifica l'elecció de percentils per separar experts i amateurs.

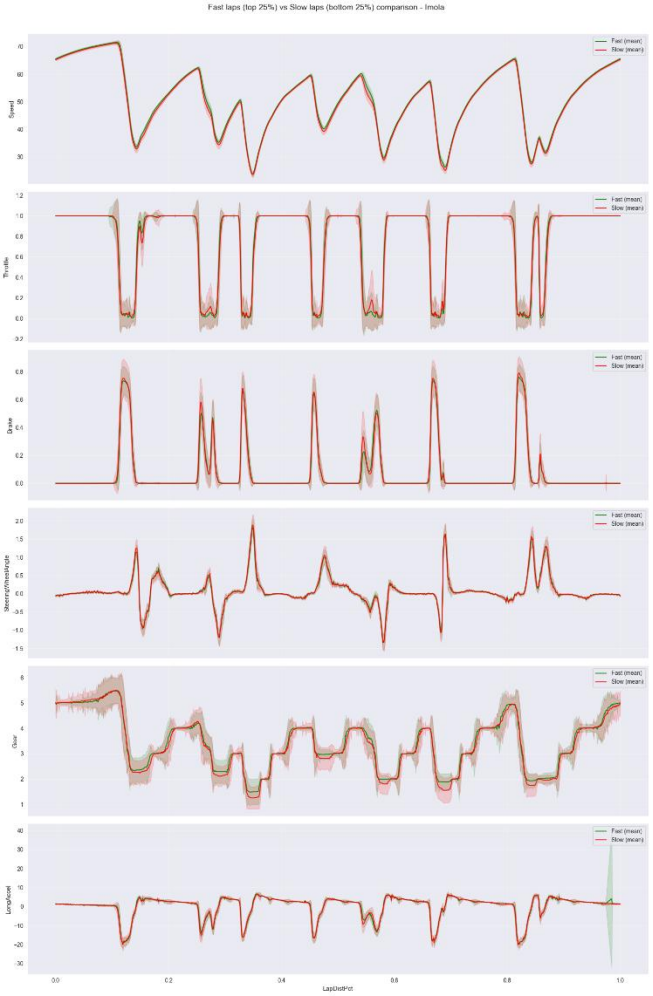


Figura A.2: Comparació dels canals de telemetria entre voltes ràpides i voltes lentes (interpolades). Permet visualitzar la major variabilitat amateur en fre i accelerador.

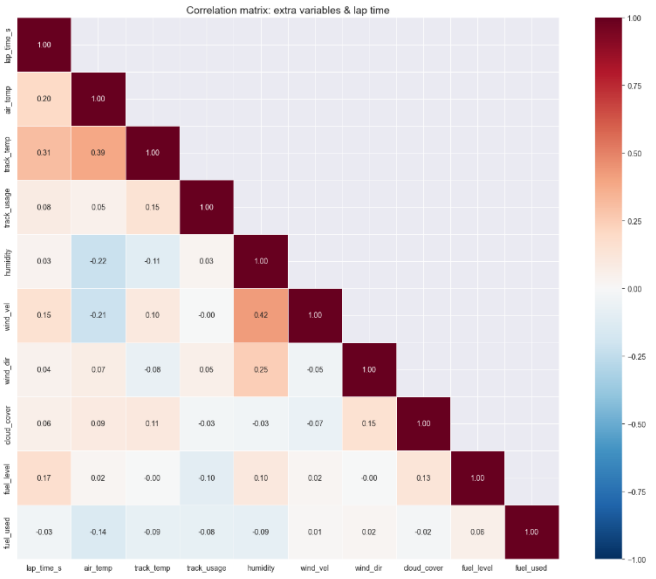


Figura A.3: Matriu de correlació entre variables ambientals i temps per volta. Dona suport al filtre ambiental del pipeline.

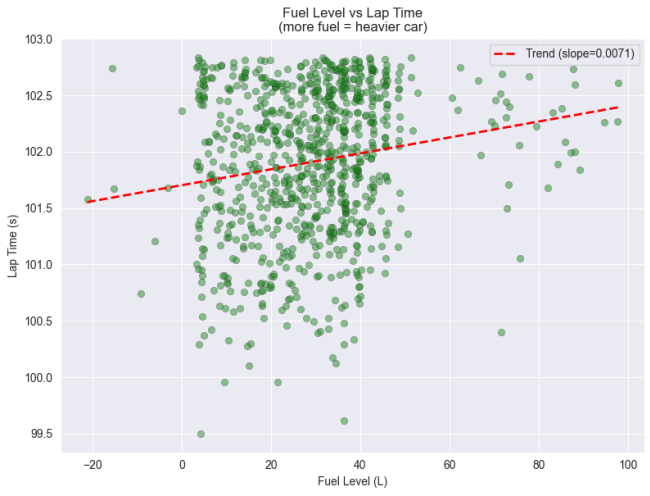


Figura A.4: Correlació entre nivell de combustible i temps de volta. Justifica la finestra de combustible aplicada a l'entrenament.

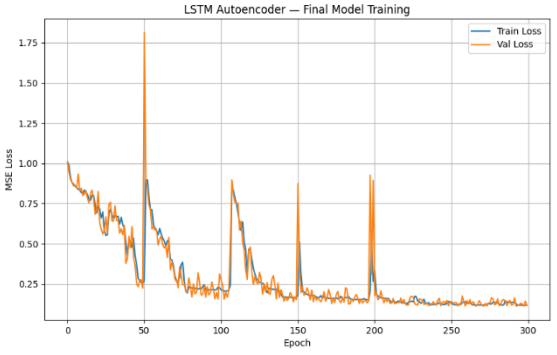


Figura A.5: Evolució de la funció de pèrdua (MSE) durant l'entrenament final. Mostra convergència i absència d'overfitting.

B. FIGURES DE LA INTERFÍCIE WEB

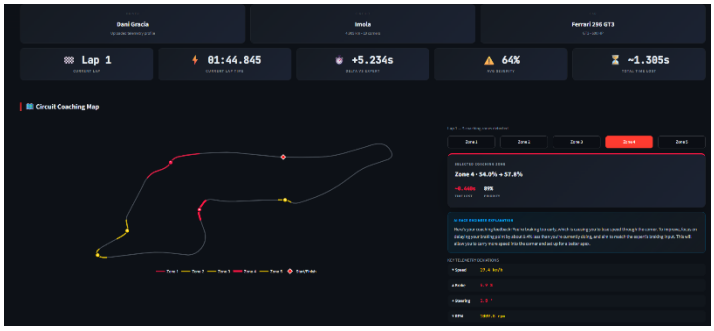


Figura B.1: Captura de Track Map amb zones codificades per severitat i inspecció de corba.

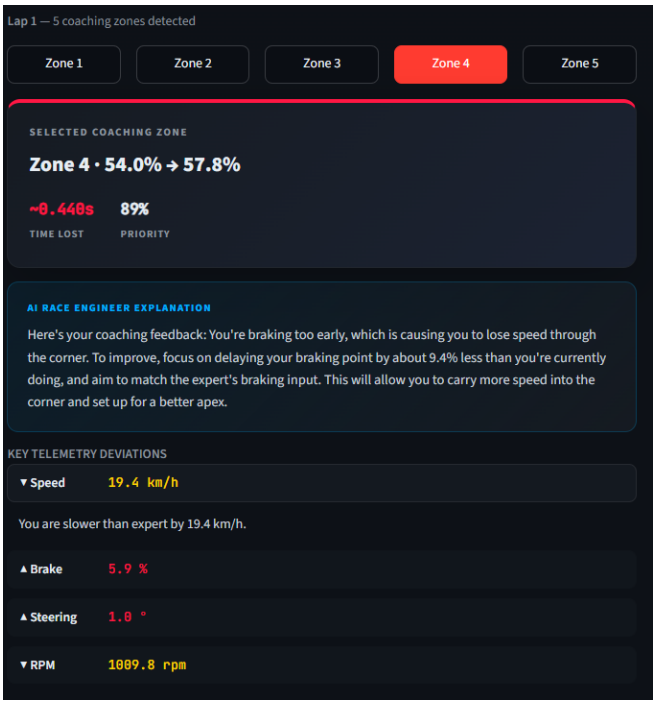


Figura B.2: Captura de AI Coaching amb consells per zona, severitat i estimació de temps perdut.

C. GLOSSARI DE TERMES TÈCNICS

Per tal de facilitar la lectura i comprensió d'aquest document, es defineixen a continuació els conceptes tècnics clau utilitzats al llarg de la memòria.

Terminologia de Motorsport i Simracing

- **Àpex:** el punt interior més profund d'una corba.
- **Simracing:** automobilisme virtual que fa servir programes de simulació altament realista per replicar amb exactitud les físiques de conducció, el desgast dels pneumàtics i la dinàmica de vehicles del món real.
- **Subviratge:** comportament dinàmic del vehicle on l'eix davanter perd adherència, provocant que el cotxe giri menys del que s'indica amb el volant i tendeixi a sortir recte cap a l'exterior de la corba.
- **Telemetria:** sistema d'adquisició, registre i transmissió automatitzada de dades físiques i dinàmiques del vehicle en moviment (velocitat, aplicació del fre, etc.).
- **VertAccel (Acceleració Vertical):** canal de telemetria que mesura els canvis de forces en l'eix vertical del vehicle.
- **YawRate (Velocitat de gir):** mesura de la velocitat angular de rotació d'un vehicle. Indica la rapidesa amb què el cotxe està rotant o canviant de direcció.

Terminologia Ciència de Dades

- **AUC (Area Under the Curve):** mètrica d'avaluació de classificadors binaris. Un valor proper a 1 indica una excel·lent capacitat del model per distingir entre una classe normal (expert) i una anòmala (amateur).
- **F1-Score:** mètrica de rendiment que combina la precisió i la sensibilitat (*recall*), oferint una mesura robusta quan les classes a classificar poden estar desequilibrades.
- **Recall:** mètrica que mesura la capacitat d'un model de classificació per identificar correctament totes les instàncies positives dins d'un conjunt de dades.
- **Overfitting (sobreajustament):** fenomen on un model aprèn massa detalls del conjunt d'entrenament, memoritzant-lo però perdent la capacitat de generalitzar davant de dades noves i desconegudes.