



**Politecnico di Torino**

Corso di Laurea Magistrale in Ingegneria Gestionale

A.a. 2024/2025

Sessione di Laurea Dicembre 2025

**STUDIO EMPIRICO DELL'AFFIDABILITÀ  
DEI VEICOLI USATI TRAMITE TECNICHE  
DI MACHINE LEARNING**

Relatore:

Prof. Maurizio Galetto

Candidato:

Luca Favero

Correlatori:

Dr. Stefano Puttero

Prof.ssa Elisa Verna



## **INDICE**

<b>LISTA FIGURE .....</b>	<b>IV</b>
<b>LISTA TABELLE .....</b>	<b>V</b>
<b>LISTA FORMULE .....</b>	<b>VI</b>
<b>INTRODUZIONE .....</b>	<b>1</b>
<b>CAPITOLO 1 - IL MERCATO AUTOMOBILISTICO .....</b>	<b>3</b>
1.1 Il mercato automobilistico nel 2025 .....	3
1.2 Il contesto europeo e la concorrenza dalla Cina .....	4
1.3 Le auto usate: un mercato in crescita in Europa e in Italia .....	6
1.4 Il problema del limone .....	7
<b>CAPITOLO 2 - L'AFFIDABILITÀ .....</b>	<b>9</b>
2.1 Affidabilità: fondamenti teorici .....	9
2.2 Modello esponenziale .....	11
2.3 Modello di Weibull .....	11
2.4 Modello di Erlang .....	13
2.5 Modello Gamma .....	13
2.6 Modello Log-normale .....	14
2.7 Affidabilità nei sistemi .....	15
2.8 Affidabilità di un autoveicolo, oltre i modelli statistici tradizionali .....	16
<b>CAPITOLO 3 - LA MANUTENZIONE .....</b>	<b>17</b>
3.1 La manutenzione: storia e definizione .....	17
3.2 Le tipologie di manutenzione .....	18
3.3 TBM – Time Based Maintenance .....	21
3.4 CBM – Condition-Based Maintenance .....	22
3.5 Diagnostica .....	23

3.6 Machine learning .....	25
3.7 Prognostica.....	31
<b>CAPITOLO 4 - LA MANUTENZIONE NEL SETTORE AUTOMOBILISTICO .....</b>	<b>34</b>
4.1 Introduzione alla manutenzione nel settore automobilistico.....	34
4.2 Le auto connesse.....	35
4.3 Telematica OEM e aftermarket .....	38
4.4 Gli standard nel settore automobilistico.....	39
4.4.1 ASAM – Association for Standardization of Automation and Measuring Systems.	39
4.4.2 VDA – Verband der Automobilindustrie .....	40
4.4.3 IATF – International Automotive Task Force .....	40
4.4.4 AIAG – Automotive Industry Action Group.....	41
4.4.5 SAE- Society of Automotive Engineers.....	41
4.4.6 AEC – Automotive Electronics Council .....	42
4.5 Come le case automobilistiche effettuano le manutenzioni .....	43
4.5.1 Volkswagen .....	44
4.5.2 BMW .....	45
4.5.3 Mercedes .....	45
4.5.4 Ford .....	46
4.5.5 General Motors .....	48
4.5.6 Toyota.....	49
4.5.7 Stellantis.....	49
<b>CAPITOLO 5 - IL CASO STUDIO .....</b>	<b>53</b>
5.1 PDR: le differenze tra vecchio e nuovo approccio .....	53
5.2 OBD-II .....	55
5.3 Gli standard legati al sistema OBD-II e la comunicazione con ECU.....	59
5.4 CANedge3.....	61

5.5 Analisi delle variabili OBD e le loro relazioni .....	62
5.5.1 Sistema di propulsione.....	64
5.5.2 Sistema frenante .....	65
5.5.3 Sistema elettrico e di accumulo .....	65
5.5.4 Variabili dinamiche, ambientali e di sintesi .....	65
<b>CAPITOLO 6 - ANALISI ED ELABORAZIONE DEI DATI DEL CASO STUDIO .....</b>	<b>66</b>
6.1 Gli algoritmi di machine learning usati nell'ambito manutentivo .....	66
6.2 La rilevazione di anomalie: Autoencoder + Random Forest + normalizzazione .....	67
6.3 Il calcolo della RUL con Autoencoder e XGBoost.....	72
6.4 Il calcolo della RUL con LSTM .....	76
6.5 Conclusioni sui modelli elaborati .....	79
<b>CAPITOLO 7 - IMPLICAZIONI PDR .....</b>	<b>80</b>
7.1 Il diritto dello sviluppo sostenibile: nascita e principi.....	80
7.2 L'applicazione del principio di correzione, in via prioritaria, dei danni alla fonte ....	81
7.3 Come il PDR potrebbe influire nell'ambito dello sviluppo sostenibile .....	82
7.4 Eco-Diagnostic.....	83
<b>CAPITOLO 8 - CONCLUSIONI.....</b>	<b>84</b>
<b>RIFERIMENTI .....</b>	<b>88</b>

## **LISTA FIGURE**

Figura 1 – Grafico che riporta le previsioni percentuali di vendite di auto ICE e EV .....	3
Figura 2 – Il valore del mercato delle auto usate in Italia 2021-2027 .....	7
Figura 3 – Andamento della funzione di affidabilità $R(t)$ .....	10
Figura 4 – Rappresentazione area sottesa rappresentante il MTTF .....	11
Figura 5 – Andamento del tasso di guasto nel modello di Weibull. ....	12
Figura 6 – Andamento del tasso di guasto al variare del parametro di forma x. ....	14
Figura 7 – Andamento dei costi delle diverse tipologie di manutenzioni .....	20
Figura 8 – Manutenzione predittiva dai dati in tempo reale delle autovetture .....	36
Figura 9 – Flusso logico che collega lo sviluppo di prodotti e servizi ai canali di vendita....	37
Figura 10 – Flusso dati in una flotta aftermarket.....	39
Figura 11 – Il ruolo di Kortical nel processo di manutenzione predittiva di FORD .....	46
Figura 12 – Modello lineare di innovazione dal manuale .....	55
Figura 13 – Dispositivo CANedge3.....	61
Figura 14 – Matrice di confusione del modello che utilizza Autoencoder e XGBoost.....	69
Figura 15 – Curva Precisione-Richiamo. ....	70
Figura 16 – Esempio di output di un'anomalia rilevata dal modello.....	71
Figura 17 – Prima parte dell'output del modello con le anomalie rilevate.....	74
Figura 18 – Analisi delle anomalie raggruppate per veicolo .....	75
Figura 19 – Veicoli in allarme individuati divisi per sottosistema dei componenti. ....	75
Figura 20 – Prima parte di output del codice. ....	78
Figura 21 – Seconda parte di output del codice.....	78

## **LISTA TABELLE**

Tabella 1 – Differenze tra TBM e CBM .....	23
Tabella 2 – Schema riassuntivo degli algoritmi di machine learning.....	30
Tabella 3 – Le 5 fasi della prognostica .....	31
Tabella 4 – Comparazione tra telematico OEM e telematico aftermarket.....	38
Tabella 5 – Tabella riassuntiva sui principali standard automobilistici.....	43
Tabella 6 – Riepilogo di come le case operino nel campo della manutenzione predittiva .	51
Tabella 7 – Schema di composizione dei codici di guasto DTC.....	57
Tabella 8 – Descrizione dei serivi dello standard J1979 .....	60
Tabella 9 – Elenco delle variabili presenti nel dataset.....	63
Tabella 10 – Spiegazione della curva precision-recall.....	68
Tabella 11 – Spiegazione output delle anomalie .....	71
Tabella 12 – Criteri per l’assegnazione del livello di priorità all’interno del modello .....	77

## **LISTA FORMULE**

[1] Definizione della funzione di affidabilità $R(t)$ .....	10
[2] Funzione di probabilità di guasto $F(t)$ .....	10
[3] Relazione tra affidabilità e probabilità di guasto .....	10
[4] Tasso di guasto (funzione di rischio) $h(t)$ .....	10
[5] Espressione del tempo medio al guasto (MTTF).....	10
[6] Definizione della funzione di affidabilità $R(t)$ nel modello esponenziale.....	11
[7] Tasso di guasto costante nel modello esponenziale .....	11
[8] Espressione del tempo medio al guasto (MTTF) nel modello esponenziale .....	11
[9] Definizione della funzione di affidabilità $R(t)$ nel modello di Weibull.....	11
[10] Tasso di guasto (funzione di rischio) $h(t)$ nel modello di Weibull .....	12
[11] Definizione della funzione di affidabilità $R(t)$ nel modello di Erlang.....	13
[12] Tasso di guasto (funzione di rischio) $h(t)$ nel modello di Erlang .....	13
[13] Definizione della funzione di affidabilità $R(t)$ nel modello di Gamma .....	14
[14] Definizione della funzione di affidabilità $R(t)$ nel modello Log-normale .....	14
[15] Tasso di guasto (funzione di rischio) $h(t)$ nel modello di Log-normale .....	15
[16] Definizione di manutenibilità $M(t)$ .....	15
[17] Definizione del tasso di riparazione $u(t)$ .....	15
[18] Formula di normalizzazione per il calcolo dello Z-score nel modello .....	67
[19] Definizione della funzione Loss di ricostruzione .....	68
[20] Definizione di F1-Score.....	68

## **INTRODUZIONE**

Il presente lavoro di tesi tratta il tema della manutenzione in ambito automobilistico, partendo dall'analisi generale del settore fino ad arrivare all'elaborazione di modelli che, tramite tecniche di machine learning, possano rappresentare un primo approccio nel processo manutentivo. Questo studio accademico è parte di un progetto, ideato da Ercole Messina e realizzato da MO.VI. S.p.A, in collaborazione con il Dipartimento di ingegneria gestionale e di produzione del Politecnico di Torino (DIGEP), che ha originariamente lo scopo di fornire un Performance Durability Rating (PDR): una misura oggettiva della vita utile rimanente di un'autovettura sulla base dei dati monitorati in tempo reale. Lo scopo finale è ottenere un sistema avanzato, integrato con intelligenza artificiale e capace di sfruttare una libreria di algoritmi per poter conseguire una valutazione della durata delle prestazioni di ciascun veicolo.

Questo elaborato espone inizialmente un'analisi del settore automobilistico, affrontando il tema di come la transizione verde ne stia cambiando i principi e le gerarchie a livello mondiale, con un particolare focus sulla situazione europea e sulle motivazioni che spiegano l'aumento negli ultimi anni di vendite di auto usate endotermiche, uno dei campi in cui opera l'azienda MO.VI. S.p.A.

A partire dai fondamenti teorici dell'affidabilità e dei suoi modelli, si approfondisce il tema di come essa sia strettamente legata nel settore automobilistico al campo della manutenzione, che negli ultimi anni sta affrontando una fase di grandi cambiamenti. Non sono più usati esclusivamente i concetti di affidabilità tradizionali, i quali oggi costituiscono un punto di partenza per modelli che, tramite tecniche di machine learning e tecnologie dell'industria 4.0 (come sensori IoT, analisi di Big Data e IA), riescono a elaborare i dati in tempo reale per una gestione della manutenzione che sia basata sull'effettivo stato dell'autoveicolo e non più fondata esclusivamente su dati storici o sulla previsione dell'usura dei componenti tramite modelli tradizionali dell'affidabilità.

Il passaggio da una manutenzione Time-based (TBM) a una Condition-based (CBM) rappresenta questo cambiamento, in cui il reale stato del veicolo guida la manutenzione. Questa evoluzione permette un'ottimizzazione dei costi, una migliore organizzazione per le case automobilistiche, ma soprattutto una prevenzione dei guasti, la quale risulta di

fondamentale utilità per garantire la sicurezza dei clienti. Questo elaborato intende analizzare come oggi le case automobilistiche stiano affrontando questo passaggio, come integrino le nuove tecnologie dell’Industria 4.0 all’interno del loro sistema manutentivo, provando a coglierne possibili similitudini e differenze tra le diverse organizzazioni.

In seguito, l’elaborato si concentra sull’elaborazione di un primo modello di manutenzione predittiva fondato su dati raccolti in tempo reale dalle autovetture. Partendo dalle basi della diagnostica e della prognostica, lo scopo è analizzare come esse siano applicate nella letteratura scientifica in ambito manutentivo, con un focus in particolare sul machine learning e i suoi algoritmi. In seguito, si sono sviluppati diversi modelli che, dall’analisi dei dati sintetici in tempo reale delle autovetture, hanno portato all’identificazione dei guasti e all’elaborazione di stime di vita utile rimanente. Essi sono finalizzati a cogliere le relazioni tra le variabili anomale e fornire una chiave di lettura più ampia in ambito manutentivo, non soffermandosi sul singolo valore anomalo ma aiutando a risalire alla causa primaria del guasto, per poi successivamente elaborare una stima della vita utile rimanente (RUL) associata.

In sintesi, gli obiettivi di questo lavoro di tesi sono comprendere come le case stiano affrontando il cambiamento nell’ambito manutentivo e come stiano integrando le nuove tecnologie all’interno dei loro processi. Successivamente, iniziando da una panoramica generale, si vuole identificare dalla letteratura scientifica quali siano gli algoritmi più adatti per l’analisi dei dati che costituiranno il fondamento metodologico per il principale obiettivo della tesi: l’elaborazione di un primo modello di manutenzione predittiva in grado di cogliere le correlazioni esistenti tra le variabili rilevate in tempo reale e i codici DTC derivanti dalla centralina di un’autovettura, riuscendo successivamente a calcolare una stima associata della vita utile rimanente dei componenti.

## CAPITOLO 1 - IL MERCATO AUTOMOBILISTICO

### 1.1 Il mercato automobilistico nel 2025

Il settore automobilistico sta attraversando una profonda fase di transizione, dovuta al passaggio dalla produzione di veicoli a combustione interna ICE (Internal Combustion Engine) alle auto elettriche EV (Electric Vehicle). In questo contesto di grande cambiamento, il settore affronta una fase di incertezza, in cui è necessario da una parte fronteggiare l'esigenza di cambiamento dettato dalle normative legislative (come, ad esempio, il Green Deal europeo) e dall'altra non perdere il proprio grado di competitività rispetto ad altri settori. Secondo il report del Rocky Mountain Institute (RMI) [1] rappresentato in Figura 1, le vendite di veicoli elettrici sono destinate a crescere in modo esponenziale nei prossimi anni: entro il 2030 dovrebbero aumentare di almeno quattro volte rispetto ai livelli attuali, arrivando a rappresentare tra il 62% e l'86% del mercato automobilistico globale. Le vendite di veicoli elettrici potrebbero superare quelle di veicoli a combustione interna già nel corso del 2026. Inoltre, secondo il Global BEV Transition [2], nel primo trimestre del 2025 la quota globale delle EV ha raggiunto il 14,5%, a differenza delle ICE che hanno perso 34 punti percentuali rispetto al 2019, sostituite da tecnologie elettriche.

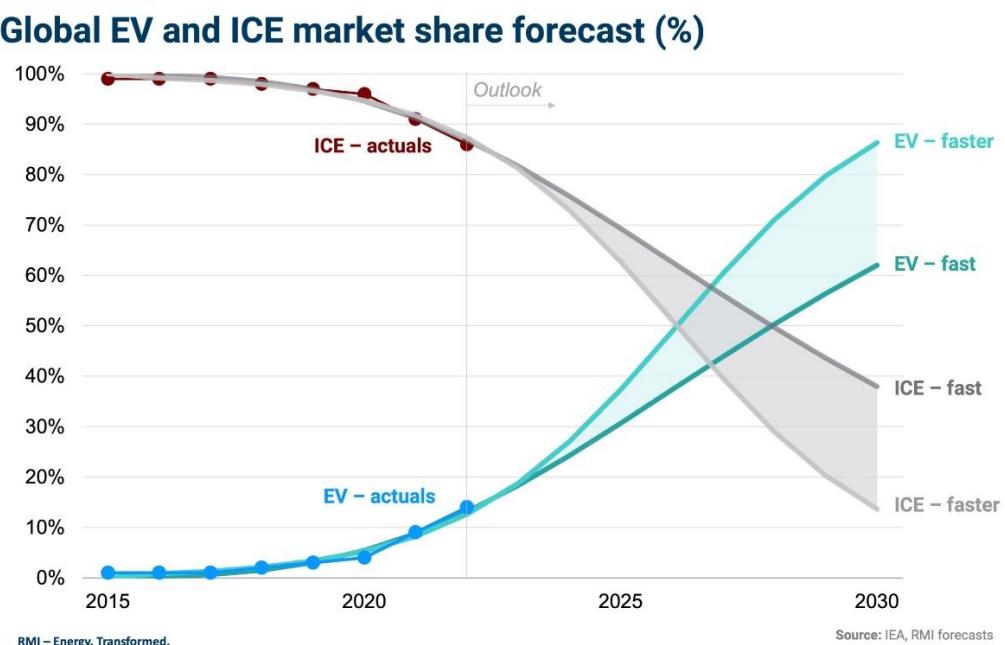


Figura 1 -Grafico che riporta le previsioni percentuali di vendite di auto ICE e EV [1].

## **1.2 Il contesto europeo e la concorrenza dalla Cina**

In questo contesto di incertezza, l'Europa si trova in una posizione complessa rispetto ad altre aree geografiche. L'industria automobilistica garantisce 13 milioni di posti di lavoro e le esportazioni di autovetture superano di 100 miliardi di euro le importazioni. Secondo il rapporto economico e di mercato di ACEA, le immatricolazioni in Europa nella prima metà del 2025 sono in calo del 2,4% e il mercato dell'UE dell'1,9%. Andando oltre i numeri, vi sono diverse ragioni più profonde dietro la posizione scomoda del continente europeo nel panorama automobilistico mondiale. Gli alti prezzi dell'energia hanno ovviamente influenzato i costi operativi legati alla produzione. La pandemia di COVID-19 ha condizionato molto il settore automobilistico dopo il 2020, causando un rallentamento nella produzione e nei trasporti. L'Europa nel suo complesso ha avuto un calo di oltre il 21% della produzione: tutti i principali paesi produttori europei hanno registrato diminuzioni che vanno dall'11% a quasi il 40%. Le tensioni geopolitiche (l'esempio principale è rappresentato dal conflitto tra Russia e Ucraina nel 2022) hanno ritardato e in alcuni casi bloccato il rifornimento di alcuni materiali critici nel settore automobilistico, come ad esempio i semiconduttori necessari per la costruzione di chip elettronici [3].

Un punto importante che amplifica questa difficoltà riguarda il progresso tecnologico: attualmente le auto non sono più un semplice mezzo di trasporto ma dei "computer a quattro ruote". Esse ormai possiedono una componentistica software molto avanzata, molteplici sensori in grado di registrare i dati del veicolo in tempo reale per poi comunicarli alle centraline. L'auto è diventata il centro di molte tecnologie e tocca i campi dell'industria 4.0: l'intelligenza artificiale, l'analisi di Big Data, l'Internet of Things. Questo comporta anche un cambiamento sia per i processi produttivi ma anche per le competenze richieste all'interno del settore: le imprese sono sempre più focalizzate nell'area dell'automazione e della digitalizzazione. Secondo lo studio "Industry 4.0 Barometer 2024", pubblicato da MHP Management, per il 52 % delle aziende europee la mancanza di personale qualificato rappresenta uno degli ostacoli più forti all'implementazione delle tecnologie dell'industria 4.0. Questa difficoltà di adozione limita la capacità produttiva e innovativa di molte imprese automobilistiche europee [4].

In contrapposizione rispetto alla situazione europea si posiziona la Cina, che domina il mercato delle auto elettriche con il 57% delle registrazioni globali, seguita da Enlarged

Europe (22%) e Usa (12%). Secondo lo stesso studio citato in precedenza [4], il 94% delle aziende cinesi ha già implementato soluzioni basate su intelligenza artificiale nei propri processi produttivi, a fronte di appena il 20% nella regione DACH (Germania, Austria, Svizzera). Dietro al dominio cinese, tuttavia, vi sono strategie mirate come le politiche di prezzo aggressive: il divario di prezzo di listino tra EV e ICE si è ridotto di circa il 15% negli ultimi sei anni, rendendo così le vetture elettriche più accessibili [2]. Questa diminuzione è dovuta all'utilizzo di batterie al litio fosfato di ferro (LFP), che garantisce una maggiore autonomia e costi di produzione inferiori. Un altro fattore determinante è stato l'alto grado di innovazione, finanziato da fondi statali hanno accelerato la digitalizzazione del settore automobilistico cinese. Inoltre, nell'ambito della formazione di competenze, nel solo 2020 in Cina ci sono stati circa 3,6 milioni di studenti nelle discipline STEM (scienza, tecnologia, ingegneria e matematica), un numero senza precedenti globalmente [4].

In un contesto in cui l'industria automobilistica europea fatica nella transizione dai veicoli a combustione interna a quelli elettrici, si inserisce un vincolo di natura legislativa importante: come stabilito dal pacchetto *"Fit for 55"*, a partire dal 2035 in tutta l'Unione Europea non si potranno più produrre auto con motore a combustione interna, con obiettivi intermedi di riduzione del 55 % delle emissioni (rispetto ai livelli registrati nel 2021) già nel 2030. L'Europa si ritrova a un bivio: i recenti dibattiti sulla fattibilità e la tempistica degli obiettivi di eliminazione graduale della combustione del 2035 riflettono le crescenti preoccupazioni sull'accessibilità, sulla competitività industriale e sulla prontezza delle infrastrutture energetiche europee [2,5].

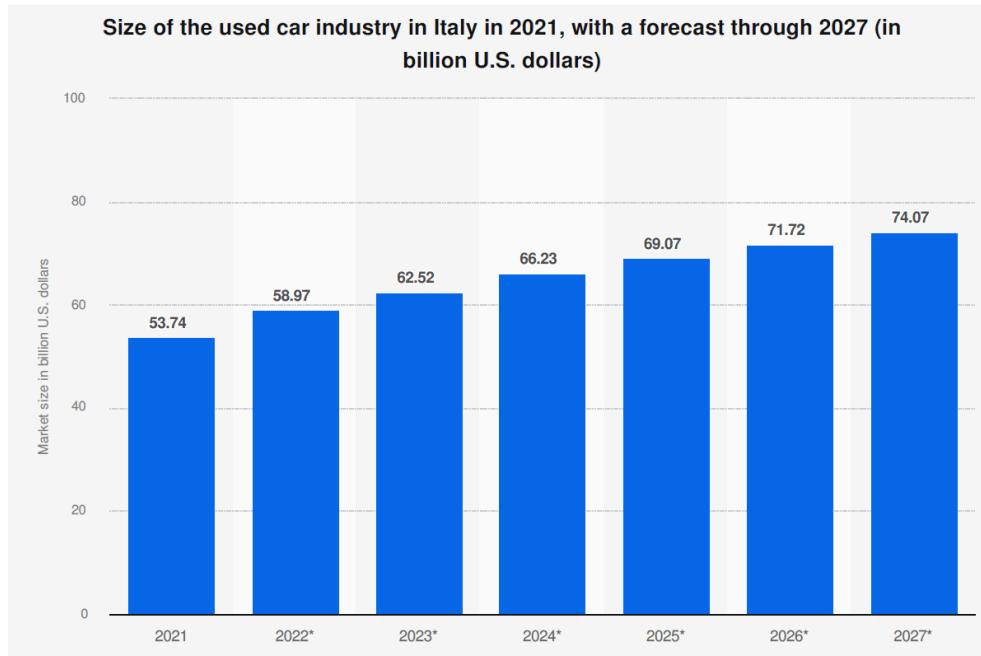
Dall'altra parte cercare di affermarsi nel campo dei veicoli elettrici non è semplice poiché l'auto elettrica costituisce un'innovazione radicale, ossia un cambiamento non solo di natura tecnologica ma una vera e propria trasformazione del paradigma tecnologico, il quale è formato dall'insieme di tecnologie, conoscenze, competenze e regole che dominano un periodo storico e ne orientano l'innovazione. Il passaggio da veicoli ICE a EV non si limita solo al cambiamento del motore: ci sono anche i materiali, i componenti, le relazioni tra gli attori del paradigma (dalle grandi lobby petrolifere ai produttori di colonnine di ricarica). La Cina dispone di un vantaggio competitivo ormai consolidato all'interno di questo paradigma riguardante la mobilità elettrica e connessa, mentre l'Europa si trova ancora in una fase di transizione, caratterizzata dalla necessità di completare il percorso verso l'autonomia

produttiva, il potenziamento della rete infrastrutturale di ricarica e l'adeguamento delle competenze digitali interne. Diventa quindi cruciale per l'Europa non rallentare nel processo di transizione verso l'auto elettrica, perché i produttori cinesi non solo hanno già consolidato una capacità produttiva, ma guidano anche l'innovazione tecnologica e godono di economie di scala che rendono l'intero mercato dell'auto elettrica sempre più monopolizzato dai colossi cinesi.

### **1.3 Le auto usate: un mercato in crescita in Europa e in Italia**

Una conseguenza della situazione automobilistica europea risiede nell'aumento delle vendite di auto usate negli ultimi anni. Questo aumento è dovuto alle crescenti difficoltà nelle vendite di auto nuove e soprattutto del ritardo da parte dei produttori europei nella produzione di auto elettriche competitive rispetto ai produttori cinesi. Altri fattori che hanno contribuito a questa situazione risiedono nelle crisi economiche e geopolitiche citate in precedenza: la pandemia di COVID-19 ha causato la chiusura temporanea di numerosi impianti di produzione automobilistica, riducendo drasticamente la disponibilità di auto nuove. La guerra in Ucraina nel 2022 ha rallentato le catene di approvvigionamento di determinate componenti fondamentali dell'auto elettrica, frenando ulteriormente la produzione di auto nuove ICE. L'incertezza economica e un calo del potere d'acquisto hanno reso l'acquisto di un'auto usata una scelta logica per molte persone, in quanto più economica e accessibile [6].

Anche in Italia, come mostrato nel grafico in Figura 2 [7], si è assistito negli ultimi anni a un aumento in termini di vendite nel mercato delle auto usate. In un panorama in cui l'acquisto di un'auto nuova è ancora fuori portata per molte persone, l'usato si impone come la soluzione più sicura e immediata che risponde direttamente alle esigenze dei consumatori.



*Figura 2 – Il valore del mercato delle auto usate in Italia negli ultimi anni e la sua previsione fino al 2027 [7].*

#### 1.4 Il problema del limone

Il mercato delle auto usate è caratterizzato da un problema di **asimmetria informativa** tra acquirente e venditore. George Akerlof ha trattato questo argomento in un articolo pubblicato nel 1970 intitolato “The Market for Lemons: Quality Uncertainty and the Market Mechanism” [8]: un documento ampiamente citato nel campo dell'economia che esplora il concetto di informazione asimmetrica nei mercati. Akerlof descrive il fenomeno della selezione avversa, che avviene nel momento in cui un soggetto, in questo caso il venditore, possiede una conoscenza superiore sul reale valore del bene a discapito dei potenziali clienti. Per illustrare questa teoria in un contesto concreto, l'autore prende come riferimento proprio il mercato delle auto usate negli Stati Uniti. All'interno dell'articolo Akerlof definisce le vetture poco affidabili come limoni (*lemons*) e quelle in ottimo stato come pesche (*peaches*). Per un acquirente è impossibile avere la certezza che il prodotto che sta acquistando sia affidabile, ovvero che sia una pesca e non un limone. Il fulcro del problema risiede proprio nel divario informativo: il venditore conosce esattamente la condizione del veicolo, mentre per il compratore essa rimane un'incognita. Ne consegue che la cifra che un cliente è disposto a spendere non rifletterà il valore di un'eventuale "pesca", ma piuttosto una media tra il valore dei beni migliori e di quelli peggiori. I venditori, quindi, godono di un netto vantaggio informativo, perché possono offrire prodotti di bassa

qualità ai segmenti di clientela meno informati nonostante, complessivamente, il mercato riconosca livelli soddisfacenti di qualità ed abbia ragionevoli garanzie di certezza. I possessori di auto di alta qualità (pesche) sono scoraggiati a immettere i loro prodotti sul mercato, perché il compenso garantito da quest'ultimo non riflette il reale valore della vettura. Di conseguenza, la presenza di prodotti di scarsa qualità (limoni) diventa sempre maggiore, portando a una riduzione della qualità generale del mercato. Questo effetto negativo a catena può spingersi fino al punto di determinare il collasso del mercato stesso, dove non sono più presenti beni di qualità superiore [8].

Risulta quindi fondamentale ridurre l'impatto dell'asimmetria informativa tramite diversi mezzi come garanzie e politiche di restituzione, certificazioni che possano garantire la qualità del prodotto e regolamenti statali, i quali tramite obblighi di trasparenza e controlli di qualità possono aumentare la fiducia nel mercato. In questo contesto emerge il concetto di **PdR**, ossia **la percentuale di durata residua**, un indicatore oggettivo e verificabile che può ridurre l'incertezza associata alla qualità del bene utilizzato (che sarà approfondito nel capitolo 4). La finalità del PdR è misurare la vita utile rimanente di un bene o di un suo componente. Se si riesce a ottenere una stima di PdR trasparente e il più possibile vicino alla effettiva vita utile rimanente del bene, l'acquirente disporrebbe di un'informazione aggiuntiva che attenua l'asimmetria informativa e garantirebbe quindi un giudizio corretto nella trattativa con il venditore. Il PdR, quindi, svolge un compito di distinzione tra i beni di qualità superiore e quelli di qualità inferiore, incentivando così la permanenza sul mercato dei venditori più affidabili. Dal punto di vista economico, qualora sia disponibile un PdR affidabile, il prezzo che gli acquirenti sono disposti a pagare può rappresentare in maniera più accurata la qualità effettiva del bene. Inoltre, il PdR, nel caso in cui possa essere certificato e standardizzato, potrebbe avere un ruolo istituzionale simile a quello delle garanzie, le quali sono comprese tra gli strumenti che Akerlof stesso aveva indicato come possibili correttori per l'asimmetria informativa [8,9].

## CAPITOLO 2 – L’AFFIDABILITÀ

Il seguente capitolo affronta le basi teoriche dell’affidabilità e i suoi modelli principali. Come verrà approfondito nei capitoli successivi, essa costituisce il fondamento teorico su cui si basa l’intero sistema di manutenzione nel settore automobilistico. Comprendere appieno l’affidabilità e i suoi modelli risulta infatti essenziale per interpretare la sua evoluzione all’interno delle moderne autovetture, nelle quali sono state integrate nuove tecnologie, tra cui spiccano gli algoritmi di machine learning.

### 2.1 Affidabilità: fondamenti teorici

L’affidabilità è, per definizione, la capacità di un oggetto di:

- 1) funzionare correttamente,
- 2) per un periodo di tempo stabilito,
- 3) in condizioni operative e ambientali fissate.

Gli elementi 1, 2 e 3 sono le variabili capaci di influenzare l’affidabilità. In termini più generali, l’affidabilità riguarda il funzionamento senza guasti degli oggetti. Per passare dal concetto teorico a quello pratico, è necessario quantificare il concetto di affidabilità, passando dalle sue caratteristiche, le quali consistono in grandezze usate per esprimere l’affidabilità numericamente [10].

L’affidabilità  $R(t)$  è la probabilità che un oggetto funzioni correttamente per un periodo di tempo  $t$  e in condizioni operative e ambientali fissate.  $R(t)$ , essendo una probabilità, è un numero adimensionale. Il funzionamento corretto di un oggetto è un concetto complementare al guasto, caratterizzato dalla cessazione della capacità di un oggetto di fornire la prestazione richiesta. Con  $t_g$  viene definita la “vita” di un oggetto, ossia il tempo in cui esso garantisce prestazioni fino al momento in cui si guasta.  $t_g$  rappresenta la determinazione della variabile casuale  $T$ , definita come il tempo fino al guasto. Considerando come variabile il tempo intercorrente tra l’istante iniziale di osservazione e l’istante di guasto  $T$ , si definisce la densità di probabilità di guasto come la funzione  $f(t)$  tale che la probabilità infinitesima che l’elemento si rompa al tempo  $t$  o in un suo intorno infinitesimo  $dt$  [10]. L’area sottesa alla densità di probabilità  $f(t)$  è uguale all’unità se il

limite temporale superiore è posto all'infinito, dato che un elemento tende prima o poi a guastarsi:

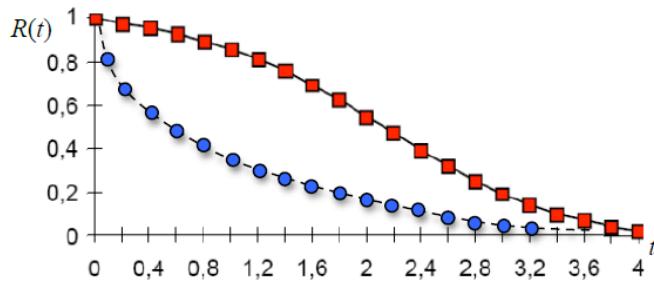
$$f(t) = \int_0^\infty f(t)dt = 1 \quad [1]$$

La probabilità che l'elemento funzionante all'istante iniziale si guasti entro l'istante di tempo  $t$  è data da:

$$F(t) = \int_0^t f(x)dx \quad [2]$$

L'affidabilità, il cui andamento è rappresentato nella Figura 3 [10] quindi risulta essere:

$$R(t) = 1 - F(t) = \int_t^\infty f(x)dx \quad [3]$$



Vale la condizione:  $0 \leq R(t) \leq 1$  per  $t = 0 \rightarrow R(t) = 1$  ( $R(0) = 1$ )  
per  $t \rightarrow \infty \rightarrow R(t) = 0$  ( $R(\infty) = 0$ )

Figura 3 – Andamento della funzione di affidabilità  $R(t)$  [11].

Un'altra caratteristica fondamentale dell'affidabilità è il tasso di guasto  $h(t)$ , ossia il rapporto fra la probabilità che ha un oggetto di guastarsi nell'intervallo tra  $t$  e  $t+dt$ , dato che non si è guastato prima di  $t$ , e la durata di detto intervallo.

$$\text{Prob}(t < T + dt | T > t) = \frac{\text{Prob}(t < T \leq t + dt \cap T > t)}{\text{Prob}(T > t)} = \frac{\text{Prob}(t < T \leq t + dt)}{\text{Prob}(T > t)} = \frac{f(t)dt}{R(t)} = h(t)dt \quad [4]$$

La terza caratteristica è il MTTF (Mean Time To Failure), ossia il valore medio della variabile casuale  $T$ . Esso rappresenta il tempo medio fino al guasto ed è fornito dall'area sottesa dalla curva di affidabilità, visualizzabile nella Figura 4 [10].

$$MTTF = \int_0^\infty tf(t)dt = \int_0^\infty R(t)dt \quad [5]$$

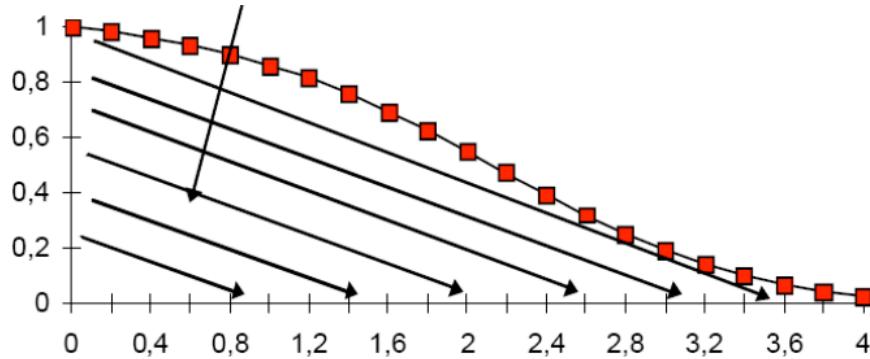


Figura 4 – Rappresentazione dell'area sottesa alla curva di affidabilità rappresentante il MTTF [11].

Nello studio dell'affidabilità sono presenti molti modelli relativi alla variabile casuale T nei seguenti paragrafi si riportano quelli più rilevanti e usati [10,12].

## 2.2 Modello esponenziale

Nel modello esponenziale l'affidabilità è espressa come:

$$R(t) = e^{-\lambda t} \quad [6]$$

Il modello esponenziale si basa su un'unica ipotesi cruciale: il tasso di guasto  $h(t)$  è costante nel tempo. Il tempo medio atteso per un guasto è l'inverso del tasso di guasto.

$$\lambda(t) = \lambda \quad [7]$$

$$MTTF = 1 / \lambda \quad [8]$$

Il modello esponenziale è un modello molto semplice, che richiede la stima del solo parametro  $\lambda$ . Tuttavia, non è adatto per modellare l'usura o l'affaticamento. I componenti meccanici (come cuscinetti, frizioni) hanno tipicamente un tasso di guasto che aumenta con il tempo. Usare l'esponenziale in questi casi porterebbe a sovrastimare l'affidabilità a lungo termine [10].

## 2.3 Modello di Weibull

Nel modello di Weibull, l'affidabilità è espressa come:

$$R(t) = \begin{cases} e^{\left\{-\frac{(t-\gamma)^{\beta}}{\eta}\right\}}, & \text{per } t > \gamma \\ 1, & \text{per } t < \gamma \end{cases} \quad [9]$$

$\gamma$  = vita minima, ossia il periodo di tempo entro il quale non capitano guasti;

$\eta$  = vita caratteristica e rappresenta un parametro di scala che allunga o accorcia l'asse del tempo;

$\beta$  = parametro di forma e controlla la forma della funzione del tasso di guasto  $\lambda(t)$ :

- $\beta < 1$ , tasso di guasto decrescente nel tempo
- $\beta = 1$ , tasso di guasto costante, la Weibull si riduce alla distribuzione esponenziale.
- $\beta > 1$ , tasso di guasto crescente nel tempo maggiore è  $\beta$ , più rapidamente il tasso di guasto aumenta.

$$h(t) = \begin{cases} \frac{\beta}{\eta} \left[ \frac{t-\gamma}{\eta} \right]^{\beta-1}, & \text{per } t > \gamma \\ 0, & \text{per } t < \gamma \end{cases} \quad [10]$$

L'andamento del tasso di guasto nel modello di Weibull è riportato in Figura 5: esso è caratterizzato da tre fasi distinte: il periodo di rodaggio (o mortalità infantile), il periodo di vita utile e infine il periodo di usura [12].

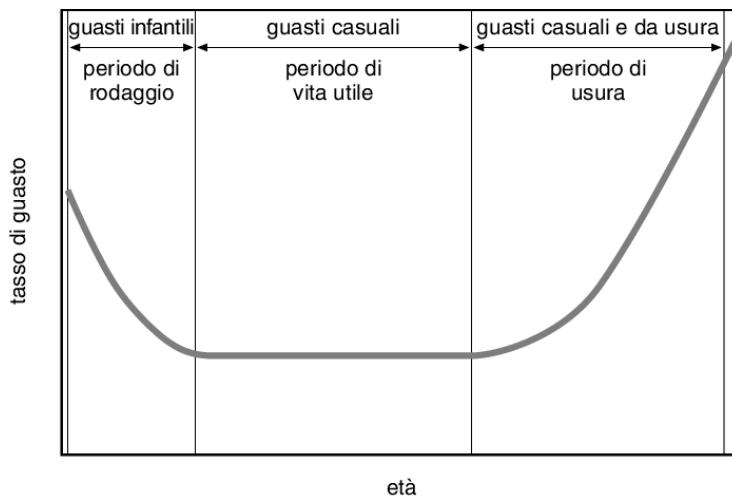


Figura 5 – Andamento del tasso di guasto nel modello di Weibull.

Nella prima fase, chiamata “mortalità infantile”, il tasso di guasto diminuisce in modo esponenziale con l'età. Il valore di  $\beta < 1$  implica che l'esponente ( $\beta-1$ ) nella formula di  $\lambda(t)$  sia negativo, causando una decrescita giustificata dal fatto che i guasti siano causati da difetti latenti o errori di fabbricazione presenti sin dall'inizio. Con l'avanzare dell'età, le unità difettose vengono eliminate, lasciando una popolazione residua composta da unità intrinsecamente più robuste.

La vita utile è una fase in cui il tasso di guasto è costante: infatti il valore  $\beta = 1$  rende il tasso di guasto  $\lambda(t)$  una costante pari a  $1/\eta$ . La distribuzione di Weibull diventa quindi esponenziale. In questa fase i guasti possono avvenire ovviamente, ma in modo casuale e imprevedibile e non sono correlati con l'età del componente.

L'ultima fase, denominata periodo di usura, rappresenta il momento in cui il valore di  $\beta > 1$  rende l'esponente  $(\beta - 1)$  positivo, determinando così una crescita di  $\lambda(t)$ , che accelera nel periodo in cui il componente invecchia. Questo comportamento modella il fenomeno dell'usura e del degrado dei materiali. Identificare un  $\beta > 1$  è un segnale chiaro per implementare una strategia di manutenzione sostitutiva preventiva, poiché i guasti diventano inevitabili e prevedibili con l'avanzare del tempo [12].

## 2.4 Modello di Erlang

Nel modello di Erlang, l'affidabilità è rappresentata dalla formula:

$$R(t) = \sum_{n=0}^{k-1} \frac{(\lambda t)^n e^{-\lambda t}}{n!} \quad [11]$$

- $\lambda$  è il tasso di guasto per ciascuna fase,
- $k$  è un intero positivo che rappresenta il numero di fasi.

L'espressione del tasso di guasto:

$$h(t) = \frac{\lambda^k t^{k-1} e^{-\lambda t}}{\sum_{n=0}^{k-1} \frac{(\lambda t)^n e^{-\lambda t}}{n!}} \quad [12]$$

È crescente con il tempo  $t$ ; nullo per  $t=0$  e tende a  $\lambda$  quando  $t$  tende a  $\infty$ .

In termini pratici, il modello elabora il tempo necessario per il completamento di  $k$  attività sequenziali, ciascuna delle quali ha una durata esponenziale indipendente e identicamente distribuita. Quando  $n=1$  la distribuzione di Erlang si riduce a una distribuzione esponenziale [10].

## 2.5 Modello Gamma

Nel modello Gamma, l'affidabilità è rappresentata dalla formula:

$$R(t) = \frac{\lambda^x}{\Gamma(x)} \int_t^\infty r^{x-1} e^{-\lambda r} dr \quad [13]$$

La formula del tasso di guasto:

- $x$  è il parametro di forma. Determina la forma della distribuzione.
- $\lambda$  è il parametro di velocità.
- $\Gamma(x)$  è la funzione Gamma, che generalizza il concetto di fattoriale ai numeri reali.

La distribuzione Gamma è una distribuzione di probabilità continua a due parametri che modella il tempo necessario affinché si verifichino  $x$  eventi (o guasti) in un processo di Poisson, dove ogni evento ha un tempo distribuito esponenzialmente. Nella Figura 6 è riportato l'andamento del tasso di guasto:

- nel momento in cui  $x > 1$ , il tasso di guasto parte da 0, è crescente e tende al valore  $\lambda$  per  $t \rightarrow \infty$ ;
- nel momento in cui  $x < 1$ , il tasso di guasto tende a  $\infty$  per  $t \rightarrow 0$ , è decrescente e tende al valore  $\lambda$  per  $t \rightarrow \infty$  [10,12].

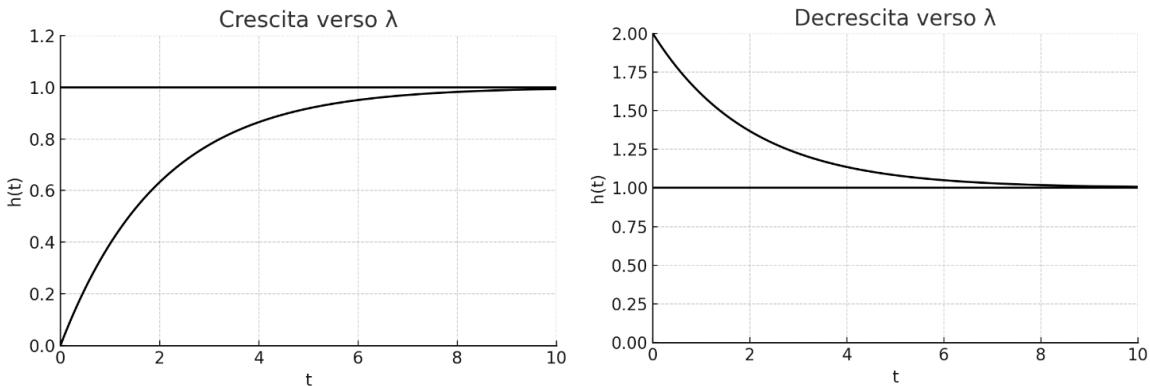


Figura 6 - andamento del tasso di guasto nei casi in cui il parametro di forma  $x$  è rispettivamente maggiore e minore di 1.

## 2.6 Modello Log-normale

Il modello Log-normale descrive la distribuzione del tempo a guasto, in cui vi è un accumulo di piccoli effetti casuali nel tempo (ad esempio, l'usura di un materiale). L'affidabilità è rappresentata dalla formula:

$$R(t) = \frac{1}{\sigma\sqrt{2\pi}} \int_t^\infty e^{-\frac{1}{2}\left[\frac{\ln r - u}{\sigma}\right]^2} \frac{dr}{r} \quad [14]$$

Il tasso di guasto, nullo per  $t=0$ ; è crescente con  $t$  e poi, dopo un massimo, decrescente al crescere di  $t$  [10,12].

$$h(t) = \frac{e^{-\frac{1}{2}\left(\frac{\ln t - u}{\sigma}\right)^2}}{t \int_t^{\infty} e^{-\frac{1}{2}\left(\frac{\ln r - u}{\sigma}\right)^2} \frac{dr}{r}} \quad [15]$$

## 2.7 Affidabilità nei sistemi

Da un punto di vista affidabilistico, un sistema è un oggetto composto da altri oggetti. Esso è formato da gruppi (unità), i quali sono formati da sottogruppi (componenti). I componenti sono l'elemento funzionale non ulteriormente scomponibile. I sistemi possono essere classificati in:

- sistemi non ridondanti, che risultano guasti se si guasta un'unità;
- sistemi ridondanti, che non si guastano se si guasta un'unità;
- sistemi non riparabili, che non vengono riparati quando si guastano essi stessi o un'unità;
- sistemi riparabili, che vengono riparati quando si guastano essi stessi o un'unità.

Nel momento in cui un sistema o una parte di esso si guasta, necessita un tempo di riparazione, che comprende diverse attività come l'individuazione del guasto o la ricerca di eventuale disponibilità per i ricambi. Il tempo occorrente per la riparazione è una variabile casuale  $T_r$  che inizia nell'istante di guasto. La manutenibilità  $M(t)$  è la probabilità che un guasto sia riparato in un certo tempo  $t$  specifico, quando le riparazioni sono fatte in accordo con procedure definite:

$$M(t) = P[T_r < t] \quad [16]$$

Il valore medio della variabile casuale è detto MTTR, ossia "Mean Time To Repair". Analogamente con l'affidabilità e il tasso di guasto, anche per la manutenibilità è possibile definire il tasso di riparazione  $u(t)$ , che è dato dal rapporto tra la probabilità condizionata di riparazione nell'intervallo  $t-t+dt$  e la durata dell'intervallo stesso  $dt$  [10].

$$u(t) = \frac{P[t < T_r < t+dt | T > t]}{dt} \quad [17]$$

## **2.8 Affidabilità di un autoveicolo, oltre i modelli statistici tradizionali**

Inizialmente, l'affidabilità aveva lo scopo di garantire che i sistemi durassero nel tempo usando **modelli statistici tradizionali**. Tuttavia, i modelli tradizionali di affidabilità non sono più adatti ai veicoli moderni a causa della varietà e della dinamicità dei dati raccolti e delle situazioni che essi gestiscono.

Proiettata nel contesto automobilistico, l'affidabilità di un'autovettura è la probabilità che i componenti e di conseguenza l'intero sistema funziona senza guasti in condizioni operative definite e per un certo periodo o chilometraggio. Vi è una classificazione dei guasti in base alla conseguenza a cui essi conducono: un guasto di primaria importanza, come un guasto al motore, rende l'auto inutilizzabile. Un guasto di secondaria importanza, ad esempio un tachimetro rotto, compromette una funzionalità specifica del sistema senza fermare il veicolo. I più gravi sono i guasti critici che mettono a rischio l'incolumità del conducente e dei passeggeri [13, 14].

La gestione di questa complessità e la precisa classificazione delle tipologie di guasto hanno favorito l'adozione di metodologie di **machine learning**. Approcci di apprendimento supervisionato e tecniche di analisi delle serie temporali abilitano l'elaborazione dei volumi di dati multimodali generati dai sistemi sensoristici di bordo. Il valore distintivo di questi strumenti risiede nella loro capacità di individuare pattern ricorrenti e anomalie sottostanti che risulterebbero non rilevabili attraverso l'ispezione umana o i convenzionali modelli statistici, potenziando così le capacità predittive e gestionali verso ogni forma di malfunzionamento.

## CAPITOLO 3 - LA MANUTENZIONE

In questo capitolo saranno spiegati i principi manutentivi fondamentali. Dopo aver analizzato le basi dell'affidabilità, ora sarà approfondita **la manutenzione**: uno strumento mediante il quale si mantiene il livello di affidabilità progettato. La relazione tra questi due concetti è di fondamentale importanza: la manutenzione può migliorare l'affidabilità di un asset in caso di degrado, riportandolo al livello di progettazione, ma non può aumentare il livello di affidabilità di un asset oltre questo livello prestabilito [15].

### 3.1 La manutenzione: storia e definizione

Negli anni, il concetto di manutenzione ha subito profondi cambiamenti dovuti allo sviluppo tecnologico e ai diversi contesti in cui è stato applicato. Durante l'era preindustriale, ad esempio, consisteva in un'attività prevalentemente manuale svolta dagli stessi utilizzatori per curare e mantenere tali strumenti. La manutenzione attuale, al contrario, emerse con la prima rivoluzione industriale con l'obiettivo di garantire che i macchinari industriali potessero funzionare correttamente il più a lungo possibile. Nel 1930 ci furono i primi esperimenti di manutenzione preventiva: a causa dell'aumento del volume della produzione industriale, divenne fondamentale pianificare il tempo e i modi necessari per proteggere i macchinari e impedirne i fermi macchina. Nel 1970 in Giappone, il Total Productive Maintenance veniva introdotta con l'obiettivo di prevenire i guasti e di migliorare l'efficacia complessiva dell'organizzazione aziendale, attraverso il coinvolgimento di tutto il personale nelle attività di manutenzione. Oggi, grazie all'utilizzo di tecnologie avanzate come sensori IoT e algoritmi di intelligenza artificiale, è sempre più diffusa la manutenzione predittiva, che non si limita all'individuazione del guasto, ma calcola anche la probabilità che un componente si guasti e quindi il tempo residuo di funzionamento dello stesso.

La definizione di manutenzione ha avuto profonde variazioni negli anni. Nel 1963 l'OCSE (Organizzazione per la Cooperazione e lo Sviluppo Economico) l'ha definita come la *"funzione aziendale alla quale sono demandati il controllo costante degli impianti e l'insieme dei lavori di riparazione e revisione necessari ad assicurare il funzionamento regolare e il buono stato di conservazione degli impianti produttivi, dei servizi e delle attrezzature di stabilimento"* [16,17].

Successivamente la norma europea UNI EN 13306, entrata in vigore dall'8 febbraio 2018, definisce la manutenzione come la "*combinazione di tutte le azioni tecniche, amministrative e gestionali, durante il ciclo di vita di un'entità, volte a mantenerla o riportarla in uno stato in cui possa eseguire la funzione richiesta*". Secondo questa norma essa ha quindi la finalità di massimizzare l'efficienza e soprattutto minimizzare gli intervalli di fermo e i casi di malfunzionamento [18].

### 3.2 Le tipologie di manutenzione

Le tipologie di manutenzione sono molteplici: in una prima suddivisione possono essere definiti due tipi di manutenzione: **manutenzione ordinaria**, divisa in correttiva e preventiva, e **manutenzione straordinaria**.

Secondo la norma italiana UNI 11063:2017, la **manutenzione ordinaria** è definita come "l'insieme degli interventi volti a conservare l'efficienza funzionale e lo stato d'uso di un bene, senza alterarne la struttura, la funzionalità o la destinazione d'uso". Essa comprende quindi l'insieme di interventi che hanno lo scopo di preservare l'integrità del sistema, garantire la vita utile del bene e far fronte ad eventi accidentali. Gli interventi della manutenzione ordinaria si caratterizzano in quanto sono regolari (definiti in intervalli prestabiliti) e preventivi (in quanto hanno lo scopo di prevenire il guasto e non risolverlo una volta accaduto). La differenza con la manutenzione straordinaria risiede nel fatto che essa mira a conservare il valore patrimoniale della macchina che, anche a seguito di interventi o modifiche volte a riparare il guasto, non viene né aumentato né diminuito. Gli interventi di manutenzione ordinaria sono spesso causati da rilevazione di guasti (correttiva), politiche di manutenzione (predittiva) oppure dalla necessità di ottimizzare la disponibilità del bene. Ad esempio, nel campo automobilistico, il cambio dell'olio e del filtro di un'automobile è un caso di manutenzione ordinaria [16].

La **manutenzione straordinaria** riguarda gli interventi che hanno l'obiettivo di migliorare le prestazioni e l'affidabilità, incrementando così il valore del macchinario dell'impianto. Essi possono prolungare la vita utile del macchinario e hanno lo scopo di prevenire l'insorgenza di un guasto. I principali interventi di manutenzione operano sul sistema strutturale oppure riguardano l'ingresso di un'innovazione radicale nel sistema tecnologico. La motivazione

dietro questa tipologia di manutenzione è legata al fatto che nel tempo i macchinari possono perdere di prestazione diventando obsoleti e non rispondendo più alle attuali esigenze che invece sono rispettate dai nuovi modelli [16].

Le principali tecniche manutentive sono: **autonoma, correttiva, preventiva e migliorativa**. Si differenziano principalmente per il momento in cui sono applicate rispetto al guasto, e per le tecnologie impiegate.

La manutenzione **autonoma** consiste in aggiustamenti e lavorazioni minori direttamente da parte degli operatori sui propri macchinari. Ogni operatore deve quindi conoscere appieno ciascuna operazione da eseguire (dalla pulizia fino alla revisione), essere formato sulle corrette competenze tecniche e deve saper definire un programma di manutenzione autonoma. Il personale ha l'obiettivo di mantenere la propria attrezzatura efficiente e di prevenirne possibili guasti. Questa tecnica manutentiva ha anche un risvolto legato alle competenze: tramite la formazione, gli operatori riescono a individuare più facilmente possibili anomalie e si può intervenire in maniera più tempestiva per gestirle e trovare una soluzione [16].

Una tipologia elementare di manutenzione è quella **correttiva**, che è eseguita nel momento in cui si verifica un guasto o la rottura di un componente, provocante un fermo macchina. La casistica, quindi, è una situazione già compromessa: si tratta di un intervento effettuato a danno già avvenuto che ha lo scopo di ripristinare le caratteristiche e le funzionalità originarie del macchinario. La manutenzione correttiva generalmente costituisce la tipologia di manutenzione più costosa, poiché l'intervento di riparazione avviene in una situazione già critica, con il rischio di tempi di ripristino più lunghi e di significative perdite di produzione [16].

La manutenzione **migliorativa** ha lo scopo non solo di ripristinare le condizioni operative ma anche di aumentare il valore di un macchinario, ottimizzandone le prestazioni e aumentandone l'affidabilità. Il suo obiettivo principale è la modifica strutturale che possa rendere l'asset più efficiente, incrementandone la produttività e riducendone i costi dell'esercizio a lungo termine. Tuttavia, questa tecnica manutentiva richiede un investimento economico significativo oltre che un'accurata pianificazione: questi due

elementi possono risultare decisivi per effettuare la corretta scelta sulla manutenzione da applicare [19].

La manutenzione **preventiva** consiste in alcune attività manutentive periodiche che hanno lo scopo di rallentare il processo di degrado di un macchinario o di un impianto. Questa tipologia manutentiva ha l'obiettivo principale di ridurre il numero di anomalie e malfunzionamenti improvvisi attraverso attività di prevenzione. Il punto fondamentale di equilibrio consiste nel corretto bilanciamento tra la manutenzione preventiva e le altre tipologie che, al contrario, attendono in modo passivo l'insorgere di un guasto. Nel settore automotive, un esempio di corretto intervento è monitorare la temperatura del liquido di raffreddamento e nel caso entri in un intervallo critico, segnalarlo al conducente in modo da evitare danni ulteriori all'autoveicolo [16, 20].

Nella Figura 7 è riportato l'andamento dei costi in funzione del numero di operazioni di manutenzione preventiva effettuate.



Figura 7 - Andamento dei costi delle diverse tipologie di manutenzioni [16].

La curva blu rappresenta il costo della manutenzione preventiva, il quale cresce proporzionalmente all'aumentare del numero di interventi di manutenzione preventiva a causa delle spese legate ai materiali, alla manodopera ed ai fermi macchina programmati. Ai lati della curva blu vi sono le due situazioni estreme di insufficienza ed eccesso di manutenzione preventiva. La curva rossa invece descrive il costo della manutenzione

correttiva, che è elevato nel momento in cui la manutenzione preventiva risulta insufficiente, ma diminuisce all'aumentare della prevenzione in quanto gli interventi più numerosi rendono i guasti meno frequenti, determinando una progressiva riduzione dei costi correttivi. Infine, la linea gialla rappresenta il costo totale di manutenzione, ossia la somma dei due precedenti. Il punto di minimo di tale traiettoria rappresenta il punto ottimale di manutenzione, in cui vi è il bilanciamento tra manutenzione preventiva e correttiva consente di ottenere l'efficienza economica.

La manutenzione preventiva a sua volta si divide in ulteriori tipologie:

- manutenzione **periodica** che si basa su cicli di utilizzi predeterminati su base temporale o ad esempio sul chilometraggio nel caso del settore automobilistico.
- Manutenzione su **condizione** che si basa sulla lettura di contatori o sul monitoraggio di specifiche metriche prestabilite. La particolarità di questa tipologia di manutenzione risiede nel fatto che essa intervenga nel momento più adeguato, evitando inefficienze dal punto di vista dei costi e delle risorse.
- Manutenzione **predittiva**, che rappresenta la tecnica più evoluta da un punto di vista tecnologico. Essa permette di monitorare lo stato di salute del proprio impianto in tempo reale e con precisione. Questa tipologia di manutenzione si avvale di una sensoristica Internet of Things per il monitoraggio e il trasferimento in tempo reale di una enorme quantità di dati (big data) che, processati da un sistema CMMS (Computerized Maintenance Management System), sono in grado di elaborare modelli che, grazie anche all'IA, calcolano il tempo residuo prima del verificarsi di un guasto. L'Intelligenza Artificiale ricopre quindi un ruolo fondamentale perché è la tecnologia che elabora i dati riguardanti efficienza produttiva, consumi energetici, caratteristiche dei componenti, tipi di guasti, soluzioni e costi nel modo più preciso possibile [16, 19].

### 3.3 TBM – Time Based Maintenance

La **Time-Based Maintenance (TBM)** è una strategia di manutenzione preventiva, basata su intervalli temporali fissi. Essa è caratterizzata da facilità di implementazione e pianificazione, permettendo di avere un programma di manutenzione prevedibile e

consentendo alle attrezzature di essere regolarmente sottoposte a manutenzione. Tuttavia, quest'ultima non si basa direttamente sul reale stato del prodotto bensì sull'assunzione che i guasti avvengano a intervalli regolari, i quali permettono di programmare gli interventi in anticipo. Questa pianificazione consente un'allocazione efficiente delle risorse e consente di prolungare la durata delle apparecchiature grazie a una gestione costante dell'usura. Tuttavia, la TBM presenta diversi limiti, tra cui spicca sicuramente il rischio di una manutenzione eccessiva e non necessaria che può comportare un aumento dei costi inutile [21].

### **3.4 CBM – Condition-Based Maintenance**

La **Condition-Based Maintenance (CBM)** è un approccio manutentivo che ha lo scopo di intervenire solo nel momento in cui si raggiunge una condizione che rende necessario l'intervento manutentivo. La grande differenza con la TBM risiede nel fatto che la CBM monitora e individua i guasti imminenti delle apparecchiature, in modo che la manutenzione possa essere programmata in modo proattivo quando necessario, e non prima. Questo approccio consente di evitare interventi superflui e permette di programmare quelli necessari, andando così a ridurre i costi relativi alla manutenzione. Inoltre, intervenendo in anticipo prima del possibile guasto, si evitano fermi macchina costosi aumentando l'affidabilità del macchinario. Infine, la CBM permette di ottimizzare le risorse materiali e di personale, evitando sprechi inutili riguardanti interventi manutentivi non necessari. Nella Tabella 1 sono riportate le differenze principali tra TBM e CBM [22]. La CBM integra diagnostica e prognostica con lo scopo rispettivamente di rilevare in tempo reale le anomalie e successivamente prevedere la vita residua dei componenti, al fine di intervenire in modo tempestivo per ottimizzare l'affidabilità dei sistemi.

Tabella 1 – Differenze tra TBM e CBM.

Criterio	TBM (Time-Based Maintenance)	CBM (Condition-Based Maintenance)
<b>Monitoraggio delle attrezzature</b>	Le attrezzature non sono monitorate in tempo reale	Le attrezzature sono monitorate in tempo reale
<b>Tempistica della manutenzione</b>	Manutenzione eseguita a intervalli prestabiliti, indipendentemente dalle effettive condizioni dell'attrezzatura	Manutenzione viene avviata in base alle condizioni in tempo reale dell'attrezzatura
<b>Implicazioni sui costi</b>	Può portare a manutenzione eccessiva, poiché le attività sono eseguite secondo un programma fisso	La manutenzione viene eseguita solo quando necessario
<b>Complessità di implementazione</b>	Più semplice da implementare poiché si basa su programmi predefiniti	Più complessa in quanto prevede l'implementazione di sensori e la gestione di dati in tempo reale
<b>Rischio di tempi di inattività non pianificati</b>	Può causare guasti imprevisti se l'apparecchiatura si guasta prima dell'intervallo di manutenzione programmato	Riduce il rischio di tempi di inattività non pianificati affrontando i potenziali problemi non appena vengono rilevati
<b>Applicabilità a diverse apparecchiature</b>	Generalmente adatto per attrezzature con modelli di guasto prevedibili e dove è possibile applicare efficacemente azioni preventive	Efficace per apparecchiature complesse, in cui il monitoraggio in tempo reale fornisce informazioni sulle prestazioni

### 3.5 Diagnostica

La **diagnostica** è un processo di traduzione di informazioni derivanti dalla misura di parametri, che ha lo scopo di rilevare in tempo reale il degrado e i malfunzionamenti delle apparecchiature, con l'obiettivo di intervenire prima dell'accadimento di possibili guasti. Essa costituisce il complesso delle attività di analisi e sintesi che, tramite i rilevamenti di determinate grandezze fisiche della macchina sorvegliata, consentono di trarre informazioni significative sulle condizioni della macchina stessa. Le tecniche diagnostiche combinano segnali fisici e comportamentali del sistema. Gli obiettivi della diagnostica sono:

- individuazione (“detection”) del guasto;
- localizzazione (“isolation”) del guasto;
- identificazione (“identification”) del guasto [23].

Il monitoraggio delle vibrazioni (Vibration Monitoring) è una tipologia particolare di monitoraggio delle condizioni che sfrutta la vibrazione come indicatore di condizione. Ogni dispositivo meccanico genera vibrazione, ma questo effetto solitamente sfavorevole può essere sfruttato come modalità di prova non distruttiva per monitorare lo stato di salute della macchina mentre è in funzione. Essa costituisce una tecnica molto efficace per il rilevamento dei guasti nei sistemi rotanti. Il vantaggio del VM rispetto ad altre tecniche è intrinseco nella velocità con cui una vibrazione reagisce a improvvisi cambiamenti in una macchina e alla flessibilità dei sensori di vibrazione, come gli accelerometri. P. Daga e L. Garibaldi nell'articolo "Machine Vibration Monitoring for Diagnostics through Hypothesis Testing" hanno analizzato i dati di cuscinetti aeronautici ad alta velocità: in particolare, i segnali di vibrazione acquisiti da macchinari rotanti sono stati analizzati applicando test d'ipotesi al fine di rilevare la presenza di danno [24].

La termografia a infrarossi è una tecnica che utilizza una telecamera a infrarossi (o termocamera) per visualizzare e misurare l'energia termica emessa da un oggetto. Essa rileva le differenze di temperature nelle apparecchiature, andando così a identificare delle aree di surriscaldamento che potrebbero essere sinonimo di guasti elettrici o meccanici. Con questo approccio è possibile monitorare i circuiti elettrici o i dispositivi di raffreddamento, riuscendo a prevedere possibili danni anche a lungo termine. Questa tecnica diagnostica consente un'analisi a distanza non distruttiva, poiché non vi è contatto fisico con il materiale analizzato. La termografia a infrarossi permette una visualizzazione dello stato del macchinario in tempo reale e di effettuare valutazioni ponderate su eventuali anomalie termiche delle applicazioni elettriche e meccaniche: un'accurata indagine termografica consente di ottenere le misure di temperatura di un oggetto che vengono confrontate con le temperature di funzionamento "storiche", al fine di stabilire se un aumento significativo di temperatura sia legato a una compromissione dell'affidabilità dei componenti o della sicurezza dell'impianto [25].

L'analisi dell'olio consente di monitorare la presenza di contaminanti come, ad esempio, alcune particelle metalliche, le quali possono danneggiare i sistemi meccanici. Tra le principali tecniche utilizzate, vi è la spettroscopia a fluorescenza a raggi X, la quale consente di identificare e quantificare i metalli da usura. L'analisi dell'olio deve essere periodica e soprattutto integrata con altre tecniche diagnostiche al fine di ottenere una valutazione

complessiva dello stato del sistema. Zararsiz nei suoi studi ha dimostrato come l'analisi a fluorescenza a raggi X (XRF) possa essere applicata per determinare la concentrazione dei metalli d'usura negli oli lubrificanti usati, fornendo uno strumento diagnostico rapido e preciso. I risultati mostrano che la XRF è una tecnica rapida e non distruttiva adatta al monitoraggio di routine delle condizioni dei macchinari [26].

Gli ultrasuoni sono una tecnologia avanzata e versatile utilizzata nel settore petrolifero e del gas per diverse applicazioni meccaniche ed elettriche, come ad esempio il rilevamento di guasti ai cuscinetti. La tecnologia consente di misurare dati dinamici attraverso sensori sia a contatto sia senza contatto e converte le onde ultrasoniche in un intervallo udibile, consentendo all'uomo di associare i suoni al segnale misurato. Questi metodi sono fondamentali per rilevare difetti interni e valutare la qualità dei materiali in molti settori industriali, tra cui spicca quello automobilistico. Il principio fondamentale è costituito dall'emissione all'interno del materiale esaminato di onde sonore ad alta frequenza: queste ultime sono riflesse dalle discontinuità interne (crepe ad esempio) e, una volta tornate al trasduttore, vengono esaminate. L'articolo "Machinery Fault Detection Through Ultrasound Technology" esamina l'importanza della metodologia a ultrasuoni per rilevare rapidamente i guasti nei motori elettrici e nelle macchine rotanti, dimostrando che gli ultrasuoni possono rilevare guasti in fase iniziale che non sono ancora evidenti attraverso l'analisi delle vibrazioni da soli [27].

### 3.6 Machine learning

Il **machine learning (ML)** costituisce una branca dell'intelligenza artificiale che si riferisce al processo mediante il quale i computer sono in grado di riconoscere schemi ricorrenti e migliorare le proprie prestazioni nel tempo senza dover essere programmati per ogni possibile scenario. Nel campo della diagnostica generale, il ML è impiegato nell'identificazione di guasti e malfunzionamenti in sistemi complessi. Esso utilizza degli **algoritmi** sofisticati che sono addestrati per riconoscere dei pattern di dati. Lo scopo finale di questi algoritmi è la creazione di **modelli**, che saranno successivamente adoperati per effettuare previsioni e categorizzare i dati. È importante distinguere quindi il ruolo dell'algoritmo da quello del modello: l'algoritmo è l'insieme di regole usate con lo scopo di

eseguire un compito specifico, mentre il modello è il risultato dell'applicazione di un algoritmo a un set di dati [28, 29].

Il ML può essere classificato in quattro tipologie distinte: **apprendimento supervisionato, non supervisionato, semi-supervisionato e rinforzato.**

- **Nell'apprendimento supervisionato** il sistema viene addestrato su dati dotati di etichette, in cui a ogni input corrisponde un output corretto. Tramite il riconoscimento degli schemi presenti in questi dati, il modello impara a effettuare previsioni su nuovi dati non etichettati. Si costruiscono modelli di previsione che, dati alcuni input, producono output sotto forma di valori discreti, per compiti di classificazione, oppure valori continui per compiti di regressione. Questi modelli sono addestrati con lo scopo di minimizzare una funzione di perdita che misura l'errore tra le previsioni del modello e i valori reali [30].
- **L'apprendimento non supervisionato** utilizza algoritmi senza dati etichettati, quindi il sistema deve identificare autonomamente schemi e relazioni. Il modello elabora i dati e li raggruppa in cluster sulla base delle somiglianze e delle diversità trovate. La grande differenza con l'apprendimento supervisionato risiede nel fatto che il modello scopre in modo autonomo le relazioni tra i dati a disposizione, senza il bisogno di istruzioni a priori su come organizzare i dati [29].
- **L'apprendimento semi-supervisionato** costituisce un approccio ibrido tra l'apprendimento supervisionato e non supervisionato. In una prima fase il modello apprende da un piccolo set di dati e successivamente ne migliora l'accuratezza attraverso l'identificazione di modelli in un altro set di dati più ampio non etichettato [29].
- **L'apprendimento rinforzato** è un tipo di apprendimento basato su tentativi ed errori, in cui il sistema interagisce con l'ambiente e non più con un dataset fisso e prende decisioni e feedback attraverso penalità e ricompense. Il suo scopo è quindi cercare strategie al fine di massimizzare i risultati positivi. Il Q-learning impiega un agente che impara attraverso tentativi ed errori, ricevendo ricompense per le azioni desiderate e penalità per quelle sbagliate [30].

L'approccio di apprendimento supervisionato si divide principalmente in due macrocategorie di problemi: la **regressione**, che prevede valori numerici continui, e la **classificazione**, che assegna i dati a categorie discrete. La regressione è una tecnica statistica che ha lo scopo di modellare la relazione tra le variabili indipendenti e dipendenti, con lo scopo di effettuare delle valutazioni su valori futuri.

La classificazione ha il compito di fornire a un'istanza di dati un'etichetta di categoria (o classe) in base alle sue caratteristiche. Vi sono molti algoritmi di classificazione utilizzati (schematizzati in Tabella 2).

- **La regressione logistica** è un algoritmo di classificazione lineare usato per problemi binari. Essa non prevede direttamente una classe, bensì stima la probabilità che un'istanza appartenga alla classe positiva utilizzando una funzione logistica (sigmoide), che comprime l'output tra 0 e 1 [31,32].
- **Le Random Forest** sono un metodo di ensemble learning, che opera con criteri che combinano più modelli per crearne uno più robusto. Si costruisce una moltitudine di alberi decisionali durante l'addestramento e si restituisce la classe modale (per la classificazione) o la previsione media (per la regressione) dei singoli alberi. Cervantes et al. (2020) hanno evidenziato come le Random Forest siano spesso metodi di apprendimento supervisionati che si dimostrano superiori ad altri metodi, come le Support Vector Machines (SVM) in contesti con dataset di grandi dimensioni, le cui caratteristiche sono eterogenee [33].
- **Le Support Vector Machines (SVM)** sono classificatori che creano coordinate per ogni oggetto in uno spazio n-dimensionale e usano un iperpiano per raggruppare gli oggetti per caratteristiche comuni. Lo scopo dei SVM è trovare l'iperpiano ottimale (noto come confine decisionale) in grado di separare i dati di classi diverse. Le SVM utilizzano il kernel trick, che mappa implicitamente i dati originali in uno spazio di caratteristiche (feature space) a dimensionalità superiore, dove diventano linearmente separabili. Cervantes et al. (2020) hanno però mostrato come la complessità computazionale e i dataset molto sbilanciati o di grandi dimensioni possano portare al degrado delle performance di questi classificatori [33,34].
- **Il K-Nearest Neighbor (KNN)** è un algoritmo che opera secondo un principio di apprendimento basato sull'istanza (“lazy learning”), in cui si posticipa l'elaborazione

dei dati fino al momento della richiesta di una previsione. Infatti, in una prima fase l'algoritmo immagazzina un dataset di addestramento e successivamente quando si presenta una nuova istanza (dato di test) da classificare, l'algoritmo attiva la sua logica. Per ogni punto sconosciuto, l'algoritmo trova i  $k$  punti più vicini ad esso all'interno del dataset di addestramento, assegnandogli l'etichetta più presente nel gruppo di punti simili. La scelta del valore di  $K$  è determinante: con un  $K$  troppo piccolo il modello è molto sensibile al rumore portando al fenomeno dell'overfitting e con un  $K$  molto grande il modello risulta troppo complesso portando ad underfitting [33,35].

- **Il K-means clustering** è un metodo di apprendimento non supervisionato che raggruppa i dati in  $K$  cluster separati sulla base delle similarità delle loro caratteristiche. Il processo inizia impostando  $K$  centri cluster iniziali, che possono essere scelti casualmente o attraverso tecniche specifiche. Ogni punto dati viene assegnato al centro più vicino, creando  $K$  cluster. Successivamente, i centri vengono ricalcolati come la media di tutti i punti in ogni cluster. Questo processo di assegnazione e ricalcolo si ripete fino alla convergenza, di solito quando le assegnazioni dei punti smettono di cambiare. L'obiettivo è minimizzare la distanza quadratica totale tra i punti dati e i loro centri cluster, assicurando che i punti nello stesso cluster siano il più simili possibile [33,36].
- **Le reti neurali artificiali (ANN)** sono modelli computazionali il cui funzionamento si ispira alla struttura del cervello umano. I neuroni formano una rete interconnessa e contribuiscono, tramite l'invio di segnali elettrici, all'elaborazione delle informazioni da parte del cervello umano. Analogamente, una rete neurale artificiale si basa sulla collaborazione tra i neuroni artificiali, che sono moduli software chiamati nodi. I neuroni artificiali operano su tre livelli: livello di input, livello nascosto e livello di output.
  - Nel primo i nodi di input elaborano i dati, li analizzano e li trasferiscono al livello successivo.
  - I livelli nascosti prendono il proprio input dal livello di input o da altri livelli nascosti. Il loro compito consiste in una ulteriore elaborazione e nel trasferimento al livello successivo.

- Il livello di output restituisce il risultato finale dell'elaborazione attraverso la rete neurale artificiale. Può avere uno o più nodi.

Le ANN hanno dimostrato alta accuratezza e affidabilità nel diagnosticare molti tipi di guasti dei veicoli. Un modello di Wang et al., che integra l'analisi dell'intensità sonora con la ANN, si è rivelato efficace nel riconoscere i guasti da usura del motore sia da segnali stazionari sia non stazionari [37]. Sebbene le ANN possano essere molto efficaci a prevedere un risultato, sono tipicamente descritte come "scatole nere", rendendo i risultati difficili da comprendere e fidarsi. La mancanza di trasparenza dietro una tale scatola nera potrebbe scoraggiare i sistemi diagnostici guidati da ANN [38,39].

- **Il perceptron multistrato (MLP)** è una rete neurale feedforward comunemente impiegata in compiti di apprendimento supervisionato, che comprende più livelli di neuroni interconnessi che trasformano sequenzialmente i dati di input per generare l'output finale. L'articolo “A multilayer perceptron approach for condition monitoring of automobile suspension system through vibration signal” si concentra sul controllo dello stato del sistema di sospensioni di un veicolo Ford EcoSport mediante l'analisi del segnale di vibrazione, avvenuto attraverso un accelerometro montato vicino alla parte fissa del sistema di sospensioni. Inoltre, dallo studio di Khoualdia et al., l'MLP ottimizzato è stato in grado di rilevare con successo vari tipi di guasti nei motori a induzione di veicoli elettrici, inclusi barre del rotore rotte, guasti dei cuscinetti e disallineamento, sotto varie condizioni operative [33,40].
- **Le reti Long Short-Term Memory (LSTM)** costituiscono una variante specializzata delle reti neurali ricorrenti (RNN) e sono ottimizzate per elaborare dati sequenziali con dipendenze a lungo termine, come dati di serie temporali. L'architettura LSTM consiste in "celle di memoria" che hanno la capacità di ricordare o dimenticare le informazioni secondo meccanismi di forgiatura selettiva. Nella diagnosi dei guasti basata sulle vibrazioni, le reti LSTM sono utilizzate per l'estrazione di caratteristiche spaziotemporali da segnali di vibrazione multi-sensore. Un nuovo metodo basato su LSTM è stato proposto da Li et al. con la finalità di diagnosticare accuratamente potenziali guasti delle celle della batteria delle autovetture e localizzare con precisione celle con fuga termica (tutto questo considerando lo stile di guida del

guidatore). Il metodo è stato testato utilizzando un grande volume di dati del mondo reale per esaminarne la robustezza e l'affidabilità [33,41].

- **Gli autoencoder** sono una classe di reti neurali auto-supervisionate usati in compiti di apprendimento non supervisionato e riduzione della dimensionalità. La loro architettura comprende un encoder, che comprime i dati di input ad alta dimensionalità in una rappresentazione compatta, e un decoder, che ricostruisce l'input originale da questa forma compressa. Queste reti sono ottimizzate per minimizzare l'errore di ricostruzione, tipicamente quantificato da funzioni di perdita come l'errore quadratico medio. Nell'articolo “A deep learning approach to optimize remaining useful life prediction for Li-ion batteries” gli autoencoder sono combinati a una rete LSTM per l'estrazione di caratteristiche in tempo reale e la normalizzazione dei dati con lo scopo di prevedere con precisione la RUL delle batterie agli ioni di litio. La combinazione di questi due algoritmi di Machine Learning garantisce un'accuratezza della previsione costante anche in scenari con dati e condizioni operative altamente variabili [33,42].

*Tabella 2 – Schema riassuntivo degli algoritmi di machine learning approfonditi nel capitolo.*

Algoritmo	Tipologia di apprendimento	Tipologia di problema
Regressione logistica	Supervisionato	Classificazione
Random Forest	Supervisionato	Classificazione e regressione
Support Vector Machine (SVM)	Supervisionato	Classificazione (e regressione con SVR)
K-Nearest Neighbor (KNN)	Supervisionato	Classificazione e regressione
K-Means Clustering	Non supervisionato	Clustering
Reti Neurali Artificiali (ANN)	Supervisionato (ma adattabili anche ad altri contesti)	Classificazione e regressione
Multilayer Perceptron (MLP)	Supervisionato	Classificazione e regressione
Reti LSTM (Long Short-Term Memory)	Supervisionato	Classificazione e regressione su dati sequenziali (serie temporali)
Autoencoder	Non supervisionato (auto-supervisionato)	Riduzione della dimensionalità, ricostruzione, Feature learning

### 3.7 Prognostica

A differenza della diagnosi che si occupa dei guasti effettivamente presenti, la prognosi si concentra sulla previsione dei guasti futuri, stimando la RUL dei componenti. Questa costituisce il parametro centrale della manutenzione predittiva, in quanto permette di pianificare interventi mirati e tempestivi, riducendo i fermi macchina non programmati e i costi operativi. La RUL non è un numero fisso, ma una stima probabilistica, che spesso è espressa come un intervallo temporale stimato tra lo stato corrente di un componente e il momento in cui esso raggiungerà una soglia critica di degrado. Il processo di stima della RUL si articola in cinque fasi distinte e interconnesse, brevemente sintetizzate nella Tabella 3.

*Tabella 3 - Le 5 fasi della prognostica.*

FASE	DESCRIZIONE
<b>Acquisizione dei dati</b>	Consiste nella raccolta dei dati tramite i sensori, spesso non semplice in contesti industriali reali
<b>Costruzione degli indicatori di salute (HI)</b>	I dati sono poi elaborati per creare indicatori che riflettano lo stato di degrado della macchina
<b>Selezione della soglia di guasto (FT)</b>	Fase in cui si seleziona la soglia di guasto, ossia il punto in cui il macchinario deve essere sostituito o eventualmente riparato
<b>Approcci di stima della RUL</b>	La stima della RUL si può basare su diversi modelli: basati sulla fisica, sui dati e infine ibridi
<b>Metriche di valutazione</b>	Si stabiliscono le metriche per valutare l'accuratezza e l'affidabilità dei modelli di stima della RUL

- **Acquisizione di dati** - rappresenta la prima fase nella stima della RUL di un sistema o di un componente. Lo scopo è la raccolta di dati affidabili che siano rappresentativi del comportamento operativo del sistema. I dati possono essere raccolti tramite varie modalità: ad esempio tramite sensori IoT in tempo reale che trasmettono informazioni sulle condizioni delle attrezzature, oppure sistemi di monitoraggio da remoto. Una volta acquisiti, i dati sono poi oggetto di una fase di preprocessing, che ha lo scopo di:
  - pulire i pattern dai valori mancanti e dagli outlier;
  - normalizzare i dati raccolti;
  - interpolare i dati per uniformare la frequenza di acquisizione.

- **Costruzione indicatori di salute** - gli indicatori di salute sono misure utilizzate per valutare la condizione di degrado del componente o del sistema, con l'obiettivo di prevedere il momento in cui si raggiungerà una soglia di guasto. L'indicatore di salute può essere il risultato dell'aggregazione di vari indicatori oppure una discrepanza tra il modello di funzionamento normale previsto e i dati reali. Esso incorpora quante più informazioni possibili, basandosi su molteplici segnali [43].
- **Selezione della soglia di guasto** - la determinazione di una soglia di guasto indica all'utente il momento in cui un sistema deve essere riparato o sostituito. Significa anche che sarà pericoloso utilizzare il macchinario oltre tale punto. Gli approcci prevalenti impiegati per determinare le soglie di guasto (FT) si basano principalmente su standard ISO consolidati, che stabiliscono le FT esclusivamente per un insieme limitato di HI basati su segnali meccanici, ovvero valori RMS e picchi dei segnali di vibrazione [44].
- **Approcci di stima della RUL** - la stima della RUL si basa su diversi modelli, i quali si suddividono principalmente in tre categorie.
  - Modelli Fisici, che si fondano sulla comprensione dei meccanismi di degrado del componente e modellano l'evoluzione del guasto sulla base di leggi fisiche.
  - Modelli data-driven, i quali si basano sui dati e usano algoritmi statistici e di machine learning in modo tale da costruire un modello di previsione della RUL. Essi sono particolarmente efficaci quando si dispone di grandi quantità di dati e quando i modelli fisici sono difficili da applicare.
  - Modelli ibridi, che combinano elementi da modelli fisici e data driven, superando i limiti individuali dei singoli modelli, integrando la conoscenza meccanica con le informazioni apprese dai dati [45].
- **Metriche di valutazione** - in letteratura sono analizzate metriche tradizionali come il RMSE (Root Mean Square Error), che permette di misurare gli errori numerici presenti tra la predizione e la realtà. Spesso queste valutazioni standard sono accompagnate anche da misure di incertezza, tra cui il PICP (probabilità che il vero valore della RUL rientri nell'intervallo predetto) e PINAW (ampiezza dell'intervallo di previsione normalizzata rispetto all'intervallo reale). Queste valutano nel complesso

la qualità e soprattutto l'ampiezza dell'incertezza, consentendo una stima probabilistica della RUL [45].

L'uso combinato di modelli data-driven, sistemi IoT e analisi Big Data permette di aggiornare le stime in tempo reale, migliorando l'affidabilità delle previsioni e garantendo una manutenzione basata sulle condizioni effettive dei componenti.

## CAPITOLO 4 – LA MANUTENZIONE NEL SETTORE AUTOMOBILISTICO

### 4.1 Introduzione alla manutenzione nel settore automobilistico

Nel settore automobilistico la manutenzione è fondamentale, poiché ha l'obiettivo di garantire la sicurezza e l'efficienza del veicolo nel corso del tempo. Il contesto della manutenzione automobilistica è in costante evoluzione ed è influenzato da un quadro normativo, che ha lo scopo di bilanciare la concorrenza nel mercato automobilistico con le esigenze di standard di qualità e sicurezza, oltre alle necessità di natura ambientale riguardanti le emissioni di CO<sub>2</sub> dei veicoli a combustione interna. Negli anni, le tecniche e le tipologie di manutenzione si sono evolute seguendo il progresso tecnologico e le esigenze normative: in particolare si è passati da un approccio di natura correttiva (s'interviene nel momento in cui si è verificato il guasto) a forme di manutenzione più evolute.

*“La maggior parte delle persone ritiene che il ruolo della manutenzione sia ‘riparare le cose quando si rompono, ma quando le cose si rompono la manutenzione ha fallito” (Blann, 2003).*

La citazione tratta dall'articolo “Understanding predictive maintenance” scritto da M. Blann [46] definisce il passaggio del **concetto di manutenzione anche nel settore automobilistico**. Essa non deve esclusivamente riparare, bensì deve prevenire, ossia impedire che il guasto si verifichi. Tradizionalmente, l'ambito delle attività di manutenzione è stato limitato alla fase di produzione rispetto a quella operativa. Ma con l'evoluzione del paradigma della produzione verso la realizzazione di una società sostenibile, il ruolo della manutenzione deve cambiare per tenere conto di un approccio orientato alla gestione del ciclo di vita [47].

Parallelamente la profonda trasformazione, guidata dalla digitalizzazione, che sta attraversando il settore automobilistico si riflette anche sulle strategie di manutenzione dei veicoli, le quali si stanno spostando da modelli basati su intervalli fissi (Time Based Maintenance) ad approcci predittivi condizionati dallo stato effettivo di un componente monitorato in tempo reale (Condition Based Maintenance). Come già approfondito in precedenza, il modello time-based è semplice da applicare e gestire ma presenta limiti significativi: può comportare interventi non necessari con un conseguente aumento dei costi, oppure il rischio di guasti prematuri non preventivati. Questo avviene poiché non viene considerata la reale condizione del componente, che è influenzata da molte variabili,

tra cui lo stile di guida. Le tecnologie come **Internet of Things** e **intelligenza artificiale (IA)** hanno reso possibile la valutazione in tempo reale dello stato dei componenti dell'auto vettura e la previsione di eventuali guasti, fornendo così le basi della manutenzione predittiva. Tuttavia, non tutti i componenti di un autoveicolo sono facilmente monitorabili da sensori, e lo sviluppo di modelli prognostici accurati richiede competenze multidisciplinari e investimenti consistenti. Pertanto, l'industria non ha operato una sostituzione, ma sta procedendo verso una strategia ibrida e sinergica [48].

#### **4.2 Le auto connesse**

Le auto oggi si stanno evolvendo sempre più in computer che attraversano le strade, con una varietà di software diversi incorporati. Le vetture più all'avanguardia sono dotate di una rete di sensori studiata per misurare i valori essenziali come la temperatura, la pressione, le vibrazioni, il flusso d'aria, lo stato di carica delle batterie. Come si può vedere in Figura 8, tali dati, monitorati in tempo reale, sono successivamente trasmessi alle unità di controllo elettroniche (ECU), le quali svolgono funzioni di acquisizione e preelaborazione delle informazioni. La comunicazione tra sensori ed ECU avviene attraverso bus veicolari standardizzati come CAN (Controller Area Network) o LIN (Local Interconnect Network). Le ECU elaborano le informazioni, che sono successivamente trasmesse alle piattaforme Cloud, tramite moduli di connettività integrati o il tethering dei dispositivi mobili. All'interno di questi ambienti Cloud sono solitamente presenti pipeline ETL (Extract, Transform, Load), motori analitici e sistemi di machine learning che consentono un'analisi avanzata dei dati. Tramite questo processo, nella diagnostica On-Board delle autovetture più recenti, i sistemi rilevano anomalie e attivano le segnalazioni locali [49].



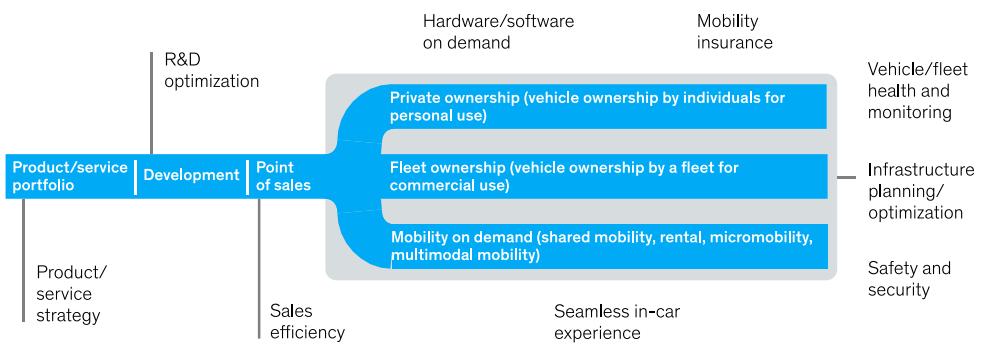
*Figura 8 - Passi per il processo di manutenzione predittiva dai dati in tempo reale delle autovetture.*

L'IoT dei sensori è un ambiente tecnologico molto dinamico che richiede un aggiornamento continuo di software e applicazioni. Esso è inserito all'interno della filosofia Agile in cui i servizi offerti sono parte di un processo dinamico di costante miglioramento. In un contesto in cui gli aggiornamenti devono essere forniti in modo continuo, un metodo ottimale è il SOTA (Software Over-The-Air): un aggiornamento del software di un dispositivo che avviene in modo remoto via Internet e, per questo motivo, non richiede che l'utente debba riportare il dispositivo al fornitore o a un'officina di supporto. SOTA rappresenta una grande semplificazione per l'utente finale ma anche una maggiore complessità per il produttore: gli aggiornamenti software devono essere forniti come download ai dispositivi idonei. Questo richiede un grande sforzo a livello di implementazione e gestione, poiché le auto oggi incorporano una grandissima varietà di software diversi e i produttori hanno quindi il compito di garantire che i loro veicoli rimangano aggiornati complessivamente. Senza il metodo SOTA, gli aggiornamenti software devono essere forniti manualmente in un'officina tramite un cavo. Nel caso in cui venga rilevato un incidente di sicurezza o un bug del software, un produttore è costretto a richiamare migliaia di auto per aggiornare il pacchetto interessato. Questo risulta inefficiente per la casa automobilistica e richiede anche tempo ai proprietari delle autovetture. Grazie a SOTA, questo processo può essere gestito tramite il Cloud, risparmiando molto tempo senza danneggiare il cliente [50].

La rete di sensori presenti all'interno dell'auto vettura consente di raccogliere una grande quantità di dati. Questi ultimi costituiscono una grande opportunità di monetizzazione, anche sulla base di come le aziende di altri settori stanno generando valore in modo aggressivo dai dati. Un'indagine nel 2020 di McKinsey sui consumatori di guida autonoma, connettività e mobilità condivisa (ACES) dimostra che il 37% degli intervistati cambierebbe i marchi automobilistici per ottenere miglioramenti in questo ambito. Il 39% dei consumatori era interessato a sbloccare funzionalità digitali aggiuntive dopo l'acquisto di un veicolo. Su questi dati alcuni assicuratori hanno tariffe assicurative su misura per gli stili di guida, ad esempio, e alcune città utilizzano i dati sensoriali per identificare le buche. Un segno del fatto che l'industria automobilistica ha già iniziato a muoversi verso la monetizzazione del ciclo di vita sono le vendite che avvengono sempre più online, con il 20-25% dei veicoli che dovrebbero essere venduti attraverso questo canale entro il 2025.

Nella Figura 9, presa dall'analisi d'indagine di McKinsey, si mostra il flusso logico che collega lo sviluppo e l'offerta dei prodotti e servizi nel settore automobilistico. L'idea chiave è l'associazione che collega lo stesso portafoglio di prodotti e processi di sviluppo (o vendita) ai tre diversi modelli di proprietà o uso: private ownership, fleet ownership, e mobility on demand [51].

**Use cases fall into nine clusters that deliver value across B2B and B2C applications.**



Source: McKinsey Center for Future Mobility

**McKinsey & Company**

*Figura 9 - flusso logico che collega lo sviluppo di prodotti e servizi ai canali di vendita [51].*

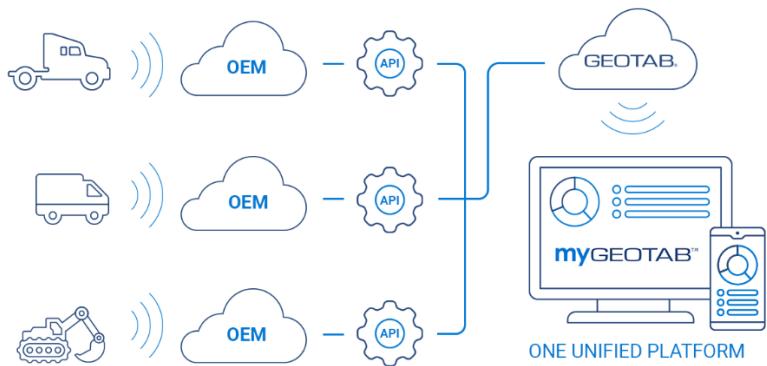
#### **4.3 Telematica OEM e aftermarket**

La telematica auto è l'integrazione di informatica, telecomunicazioni e GPS per monitorare e gestire i dati di un veicolo, di cui si è parlato nei paragrafi precedenti. La telematica può essere sia di natura proprietaria OEM, quindi integrata in fase di produzione, oppure aftermarket, in cui il sistema viene aggiunto successivamente dal cliente.

Come illustrato dalla Tabella 4, da una parte la telematica OEM offre una soluzione di gestione della flotta senza costi di installazione di dispositivi esterni, capace di accedere fin da subito ai dati proprietari OEM essenziali per ottimizzare l'integrità del veicolo e i programmi di manutenzione. Dall'altra parte una soluzione aftermarket (come quella ad esempio sviluppata da Geotab, rappresentata in Figura 10) potrebbe rappresentare una soluzione più adatta nel caso in cui la flotta comprende veicoli di diversi produttori OEM, i quali spesso utilizzano un reporting dei dati basato su frequenze diverse tra di loro. La telematica aftermarket potrebbe portare all'adozione di un'unica frequenza, in modo tale da garantire un'acquisizione di dati uniforme tra tutti i veicoli della flotta [52,53].

*Tabella 4 - Comparazione tra telematico OEM e telematico aftermarket.*

<b>Elementi di confronto</b>	<b>Telematica OEM</b>	<b>Telematica aftermarket</b>
<b>Hardware</b>	hardware telematico automobilistico integrato dall'OEM	dispositivo telematico indipendente dal produttore che viene installato in un momento successivo all'acquisto
<b>Software</b>	piattaforma Cloud che raccoglie e gestisce i dati riportati dall'hardware telematico integrato	software di gestione della flotta connesso che riceve e organizza i dati di tutti i veicoli o asset con il dispositivo telematico installato



*Figura 10 – Flusso dati in una flotta aftermarket.*

#### **4.4 Gli standard nel settore automobilistico**

Gli standard legislativi e di settore nel campo automobilistico (sintetizzati in Tabella 5) hanno un ruolo di delimitazione del contesto in cui le case definiscono le soglie di manutenzione. Infatti, questi standard non stabiliscono direttamente i requisiti di manutenzione, la cui definizione rimane in capo ai costruttori (OEM), ma si limitano a delineare il contesto e i confini entro i quali gli OEM stessi devono determinare tali soglie.

##### **4.4.1 ASAM e.V. - Association for Standardization of Automation and Measuring Systems (Germania)**

ASAM è un'associazione no-profit internazionale con sede in Germania. Tra i membri spiccano BMW, Daimler, GM, Honda, Toyota, Volkswagen e Volvo. Essa standardizza lo scambio di dati diagnostici tra ECU e strumenti esterni (officine, tool di test, sistemi di gestione flotte). Nell'ambito della comunicazione ECU, questa associazione riveste un ruolo cruciale in quanto si occupa della creazione di formati di dati, protocolli e API con lo scopo di garantire interoperabilità tra gli strumenti di simulazione, misurazione e testing delle ECU. Gli standard principali di questa associazione sono:

- ASAM ODX (Open Diagnostic Data Exchange), uno standard finalizzato allo scambio di dati diagnostici tra ECU e strumenti esterni, che regola l'integrazione tra gli strumenti di diagnosi e i sistemi delle officine ufficiali.

- ASAM MCD-3D, uno standard che permette di rappresentare segnali mappe e parametri delle ECU delle autovetture.
- ASAM XCP (Universal Measurement and Calibration Protocol), un protocollo per l'accesso in tempo reale ai segnali delle ECU e supporta metodi di trasporto come CAN-bus (Controller Area Network), standard che permette di collegare le ECU [54,55].

#### **4.4.2 VDA – Verband der Automobilindustrie (Germania)**

La VDA è un'associazione dell'industria automobilistica tedesca che rappresenta diversi OEM e fornitori. I suoi principali membri sono Audi, BMW, Daimler (Mercedes-Benz), Volkswagen, Porsche, Opel. Questa associazione definisce standard e linee guida tecniche per qualità, sicurezza, produzione e interfacce. Supporta l'innovazione e la competitività del settore automotive tedesco in Europa e nel mondo. Gli standard VDA forniscono strumenti per garantire qualità, efficienza e interoperabilità lungo tutta la catena produttiva e di manutenzione dell'industria automobilistica, supportando sia le operazioni interne ai costruttori sia la gestione dei fornitori [56, 57].

#### **4.4.3 IATF – International Automotive Task Force**

L' International Automotive Task Force, noto come IATF, è un gruppo internazionale di case automobilistiche e associazioni di categoria costituito con lo scopo di fornire prodotti di qualità ai clienti del settore. I principali membri sono BMW, Daimler, Ford, General Motors, Volkswagen, Renault, Stellantis (ex FCA/PSA), Honda, Toyota, Maruti Suzuki. Il principale standard di questo gruppo è lo standard IATF 16949, che riguarda sistema di gestione della qualità nel settore automobilistico. Esso armonizza i requisiti dei diversi OEM perché rappresenta un punto comune basato sulla norma ISO 9001, fornendo un processo uniforme di certificazione per i fornitori. Il concetto di armonizzazione dei requisiti dei diversi OEM riguarda principalmente la standardizzazione del contesto in cui nascono i CSR (Customer Service Requirements). La pubblicazione di questi ultimi, secondo lo IAFT, deve avvenire in modo documentato, monitorato e basandosi su dati assunti in prove ben definiti dagli standard. Questo concetto è fondamentale per comprendere appieno il ruolo degli standard legislativi e di settore: essi non stabiliscono direttamente requisiti o soglie di

manutenzione, la cui definizione rimane in capo ai costruttori (OEM), ma si limitano a delineare il contesto e i confini entro i quali gli OEM stessi devono determinare tali soglie [58, 59].

#### **4.4.4 AIAG – Automotive Industry Action Group (USA)**

L'AIAG è un'associazione no-profit USA che coordina OEM, fornitori, logistica e istituzioni per standard comuni. I membri risultano essere oltre ottocento, tra cui emergono Ford, GM, Chrysler, Toyota, Honda, Nissan. Questa associazione sviluppa standard su qualità, supply chain, sostenibilità, packaging, conformità e digitalizzazione. Include linee guida per la manutenzione preventiva degli impianti produttivi e il monitoraggio dei macchinari. Essa fornisce strumenti per la tracciabilità digitale dei dati di manutenzione, particolarmente per componenti critici e sistemi powertrain [60, 61].

#### **4.4.5 SAE- Society of Automotive Engineers**

Il SAE (Society of Automotive Engineers) è un'associazione professionale globale di ingegneri e tecnici, che coinvolge tutti i principali OEM ed è attiva nell'automotive, aerospazio e veicoli commerciali. Essa produce standard tecnici (es. livelli di guida autonoma, connettori, procedure di test) riconosciuti a livello mondiale. Tra i principali standard adottati (alcuni approfonditi nel paragrafo successivo) vi sono:

- SAE J1979 (OBD-II): definisce le modalità di comunicazione tra il sistema di diagnostica a bordo (OBD) di un veicolo e gli strumenti di diagnostica esterni, come i lettori di codici di errore DTC. È stato introdotto negli Stati Uniti nel 1996 e successivamente adottato a livello globale per garantire l'interoperabilità tra veicoli e attrezzature di diagnostica. Questo protocollo regola il processo per la rilevazione dei malfunzionamenti e la gestione delle emissioni nei veicoli leggeri [62].
- SAE J1939: definisce un insieme di protocolli per la comunicazione tra le unità di controllo elettroniche (ECU) nei veicoli pesanti. Basato sul protocollo Controller Area Network (CAN), esso fornisce uno standard per la trasmissione di dati tra i vari componenti del veicolo.

- SAE J3061: fornisce un quadro di riferimento per l'ingegneria della sicurezza informatica nei sistemi cyber-fisici dei veicoli. È stato sviluppato per rispondere alla crescente necessità di proteggere i veicoli da minacce informatiche [62,63].

#### **4.4.6 AEC – Automotive Electronics Council (USA)**

L'AEC (Automotive Electronics Council) è un consorzio nato da aziende automotive e si occupa di standard comuni per la qualificazione dei componenti e per i sistemi di qualità, come la serie AEC-Q per garantire l'affidabilità dei componenti elettronici. Il Comitato Tecnico per i Componenti AEC è l'organismo di normazione che stabilisce gli standard per componenti elettronici affidabili. I requisiti di questo standard si concentrano sulla resistenza a varie tipologie di stress, come quello ambientale, elettrico o meccanico. L'obiettivo finale è garantire che i componenti elettronici integrati possano fornire sicurezza e funzionalità nel lungo periodo e in condizioni operative non favorevoli. AEC-Q100 è lo standard più importante stabilito dall'AEC che conferisce al componente una certificazione a prove di stress ed è quindi garanzia di qualità e affidabilità [64,65].

*Tabella 5 - Tabella riassuntiva sui principali standard automobilistici.*

Nome	Paese e applicazione	Membri principali	Di cosa si occupa
<b>ASAM e.V. (Association for Standardization of Automation and Measuring Systems)</b>	Associazione no-profit internazionale (Germania)	BMW, Daimler, GM, Honda, Toyota, Volkswagen, Volvo	Standardizza lo scambio dati diagnostici tra le ECU.
<b>VDA (Verband der Automobilindustrie)</b>	Associazione industria automobilistica tedesca	Audi, BMW, Daimler, Volkswagen, Porsche, Opel	Definisce standard e linee guida tecniche per qualità, sicurezza, produzione e interfacce.
<b>IATF (International Automotive Task Force)</b>	Globale	BMW, Daimler, Ford, GM, Volkswagen, Renault, Stellantis, JLR, Honda, Toyota, Suzuki	Definisce standard globali di qualità e linee guida tecniche per qualità, sicurezza, produzione e interfacce.
<b>AIAG (Automotive Industry Action Group)</b>	USA	Ford, GM, Chrysler, Toyota, Honda, Nissan, Caterpillar, Navistar	Sviluppa standard su qualità, supply chain, sostenibilità, conformità e digitalizzazione.
<b>SAE International (Society of Automotive Engineers)</b>	USA e globale	Ingegneri e tecnici di tutti i principali OEM	Definisce standard tecnici nel settore automotive, aerospaziale e per i veicoli commerciali.
<b>AEC (Automotive Electronics Council)</b>	USA	Coinvolgimento OEM indiretto	Elabora standard per garantire l'affidabilità dei componenti elettronici

#### **4.5 Come le case automobilistiche effettuano le manutenzioni**

Il passaggio da una manutenzione Time-based (TBM) a una Condition-based (CBM) rappresenta il cambiamento, in cui il reale stato del veicolo guida la manutenzione. Tutti i principali gruppi automobilistici stanno adottando questo nuovo paradigma, grazie a intere divisioni software che sfruttano i dati telematici raccolti per poter elaborare strategie di manutenzione sviluppate in funzione delle condizioni reali del veicolo. Le tecnologie comprese in questo nuovo paradigma manutentivo sono principalmente i sensori IoT per la raccolta dati, il Cloud per il loro immagazzinamento e gli algoritmi di machine learning per l'elaborazione con la finalità di rilevare e predire eventuali guasti. Nella Tabella 6 sono

schematizzate tutte le informazioni presenti in questo paragrafo riguardante l'applicazione della manutenzione predittiva da parte dei principali gruppi automobilistici.

#### 4.5.1 Volkswagen

I modelli del Gruppo Volkswagen (Audi, Volkswagen, Seat, Skoda) si basano su un programma di manutenzione a intervalli prefissati. Affianco a questo sistema, CARIAD, la divisione software del Gruppo Volkswagen, ha sviluppato un sistema di manutenzione predittiva che utilizza algoritmi di machine learning per analizzare i dati raccolti dai sensori del veicolo. Gli algoritmi proprietari sviluppati da CARIAD sono in parte integrati nella Digital Production Platform DPP (Cloud industriale in collaborazione con Amazon Web Services), la quale costituisce una piattaforma centralizzata finalizzata allo sviluppo delle applicazioni basate su Machine Learning principalmente a livello industriale.

Il sistema diagnostico ufficiale proprietario del Gruppo Volkswagen è ODIS (Offboard Diagnostic Information System). Quest'ultimo, oltre alla lettura dei codici, permette coding, adattamenti, aggiornamenti software seguendo protocolli standardizzati.

Una tecnica diagnostica adottata da Volkswagen per l'identificazione di malfunzionamenti dei componenti è il Sound analyser. Sostanzialmente si tratta di diagnosi acustica con AI, in grado di registrare i suoni emessi da un veicolo in funzione e confrontarli con quelli di riferimento. Usando algoritmi neurali, l'app converte l'audio in uno spettrogramma, lo compara a modelli precedentemente memorizzati e rileva anomalie con oltre il 90% di accuratezza. Viene presa in considerazione l'acustica del veicolo, con algoritmi di pattern matching e analisi di frequenza che rilevano variazioni nei normali suoni di funzionamento.

Per la gestione delle flotte Fleet Interface Data rappresenta la soluzione "Data-as-a-Service" (DaaS), co-sviluppata da CARIAD insieme a sei brand del Gruppo (Audi, Volkswagen Passenger Cars, Volkswagen Commercial Vehicles, Škoda, SEAT e Cupra), che offre dati utili ai fleet manager per una gestione più efficiente. I dati telematici sono stati integrati inoltre nelle piattaforme di Geotab e Targa Telematics, per una migliore gestione delle flotte [66-68].

#### **4.5.2 BMW**

BMW utilizza il sistema proprietario Condition Based Service (CBS) per pianificare i tagliandi. Si tratta di una funzionalità di manutenzione intelligente che utilizza i dati in tempo reale per determinare quando è necessario un intervento di manutenzione.

Il CBS si adatta all'usura dei componenti, sul chilometraggio percorso e soprattutto sullo stile di guida del conducente. Per misurare lo stato dei componenti sono utilizzati sensori e impiegati dei modelli predittivi per stimare la vita utile rimanente, che viene mostrata in tempo reale sul display iDrive.

Inoltre, controlla i tempi e i chilometraggi consigliati per i tagliandi fissi e tramite un algoritmo interno stima il grado di usura o invecchiamento di ciascun componente:

- Se il veicolo viene usato in modo leggero (autostrada, guida costante), il sistema posticipa il tagliando.
- Se l'auto è usata in città, in modo severo (stop&go, partenze frequenti), anticipa la manutenzione.

Per alcuni componenti critici vi sono dei sistemi appositi: l'usura delle pastiglie all'interno del gruppo BMW è misurata tramite il modulo DSC (Dynamic Stability Control), che utilizza determinati parametri (tra cui pressione del freno, chilometraggio, temperatura, tempo) insieme ai sensori di usura per stimare quanto manca prima di dover sostituire le pastiglie. Il sistema Teleservices Battery Guard monitora la tensione della batteria e avvisa sia il cliente che il centro assistenza se scende sotto una soglia critica [69,70].

#### **4.5.3 Mercedes**

Anche Mercedes sta compiendo il passaggio dalla manutenzione reattiva a quella predittiva, integrando l'intelligenza artificiale nei propri veicoli. Monitorando lo stato in tempo reale di vari componenti, lo scopo è prevedere quando essi potrebbero guastarsi. Le capacità predittive dei modelli si basano su algoritmi di apprendimento automatico che analizzano i dati sulle prestazioni, sia storici sia in tempo reale, raccolti dall'ampia rete di sensori del veicolo.

Mercedes impiega il sistema **Active Service System (ASSYST Plus)** per il promemoria manutenzioni. Esso considera fattori come il comportamento di guida inteso come stile di

guida, il chilometraggio percorso, la durata trascorsa dall'ultima manutenzione e le condizioni ambientali (in particolare temperatura e umidità), con la finalità di calcolare la frequenza ottimale degli intervalli di manutenzione. I veicoli Mercedes-Benz hanno in genere due intervalli di manutenzione principali, denominati servizio A e servizio B.

- servizio A: intervento base, generalmente ogni 16.000 km;
- servizio B: intervento più approfondito, ogni 32.000 km.

I sensori IoT utilizzati per rilevare i dati in tempo reale sono integrati nella piattaforma digitale MO360, utilizzata da Mercedes Benz per la raccolta di informazioni dai veicoli e dai processi produttivi. I dati sono successivamente inviati al sistema di back-end diagnostico ufficiale di Mercedes (che identificano segnali di usura o malfunzionamenti imminenti): Xentry. Quest'ultimo è programmato per comunicare con le unità di controllo elettroniche dei veicoli, leggere e cancellare codici di errore. Risulta quindi di fondamentale importanza, nell'ambito della manutenzione predittiva, la sua capacità di diagnosticare i sistemi ed eseguire prontamente gli aggiornamenti software [71-75].

#### 4.5.4 Ford

La casa automobilistica Ford ha instaurato una collaborazione con la società di intelligenza artificiale Kortical finalizzata all'applicazione di manutenzione predittiva basata sull'apprendimento automatico applicato a dati in tempo reale. In particolare, l'obiettivo primario riguarda la riduzione al minimo dei tempi di fermo dei veicoli Ford Transit, con manutenzione programmata anziché reattiva.

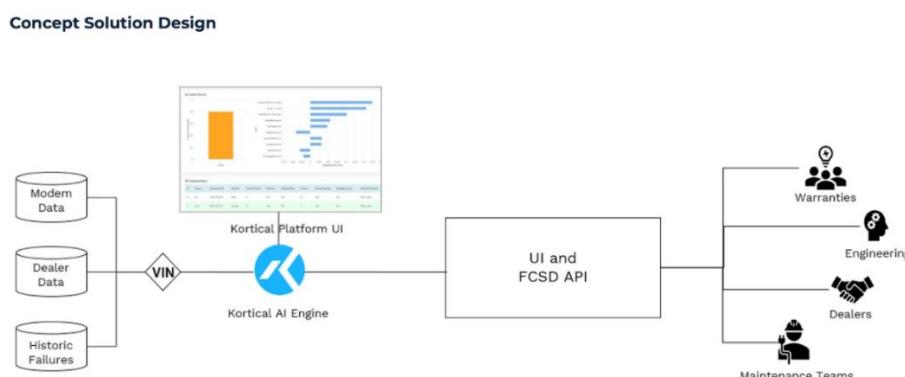


Figura 11 – Figura rappresentante il ruolo di Kortical nel processo di manutenzione predittiva di FORD.

L'integrazione con la piattaforma Kortical (Figura 11) permette di migliorare la gestione dei codici DTC: i dati del veicolo connesso portavano a numerose segnalazioni legate ai codici di guasto. Se utilizzate singolarmente, queste segnalazioni producevano un tasso di falsi positivi elevato perché un DTC si attiva in determinate condizioni anomale. Un esempio può essere un problema legato alla batteria che fa scattare l'attivazione errata di altri DTC, poiché la bassa tensione causa condizioni simili ad altre modalità di guasto. Utilizzando l'apprendimento automatico per interpretare l'intero set di dati DTC e per tenere conto di contesti più ampi come lo storico ripetizioni o i metadati del veicolo, si ottiene un tasso di falsi positivi molto più basso per ogni dato problema rispetto a quanto ottenibile utilizzando il singolo DTC. Tale integrazione ha prodotto una soluzione in grado di prevedere il 22% dei guasti, in media con 10 giorni di anticipo, con un basso tasso di falsi positivi del 2,5%.

Nell'ambito della manutenzione predittiva ottimizzata, mediante un'efficace segmentazione della flotta e un miglioramento dei processi di pianificazione, Ford ha depositato nel 2021 un brevetto che si concentra su metodi e sistemi per monitorare lo stato di salute di un componente del veicolo tramite l'analisi distribuita dei dati di funzionamento. L'approccio consiste nella suddivisione della flotta di veicoli in classi omogenee e, per ciascuna di esse, addestrare un modello predittivo dedicato, basato su dati storici. Per migliorare le prestazioni e ridurre la trasmissione di grandi quantità di informazioni al Cloud, viene adottata una strategia di apprendimento federato, in cui ogni veicolo contribuisce all'aggiornamento del modello condividendo soltanto i parametri locali. In questo modo si ottiene una maggiore tutela della privacy, una riduzione dei costi di comunicazione e una capacità di aggiornamento continuo del sistema.

Un altro esempio di questa filosofia progettuale è il sistema Ford Intelligent Oil-Life Monitor. Questo dispositivo calcola gli intervalli di cambio olio in relazione all'effettivo utilizzo del veicolo, superando il paradigma degli intervalli di manutenzione fissi e predeterminati. Gli algoritmi di bordo (On-Board), come quello dell'Intelligent Oil-Life Monitor, sono di natura proprietaria e chiusa. Il loro codice sorgente costituisce un segreto industriale ed è integralmente incorporato nel firmware delle unità di controllo elettronico Ford. Al contrario, gli algoritmi Cloud-based, sviluppati in partnership con Kortical e descritti nel brevetto, pur rimanendo proprietari, sono il frutto di uno sviluppo collaborativo [76-79].

#### **4.5.5 General Motors**

General Motors equipaggia i suoi veicoli di un sistema di monitoraggio della vita utile dell'olio (OLM, Oil Life Monitor), gestito integralmente dalla centralina motore. Esso elabora alcuni parametri operativi, tra cui ore di funzionamento, regime motore e condizioni di carico, con lo scopo di stimare il degrado e l'usura del lubrificante. Infatti, vi sono molteplici fattori che impattano sulla vita residua dell'olio e, integrando i dati in tempo reale relativi a queste variabili, l'OLM è in grado di calcolare con precisione il momento ottimale per effettuare la sostituzione del lubrificante, comunicando all'utente la percentuale di vita residua attraverso il Driver Information Center. Parallelamente ai sistemi di bordo, la diagnostica avanzata viene condotta attraverso il GDS2 (Global Diagnostic System 2), la piattaforma proprietaria e ufficiale GM riservata alla rete di assistenza autorizzata. Essa consente la scansione dei veicoli GM per la rilevazione di codici di errore ed è utilizzata dal 2014. Questa piattaforma è integrata con il Service Programming System (SPS), con lo scopo di aggiornare i moduli di controllo all'interno del veicolo.

Come altri gruppi automobilistici, anche General Motors ha implementato strumenti di IA sia nell'ambito del controllo qualità della produzione sia nel campo della manutenzione predittiva, grazie alla rete di sensori e algoritmi predittivi, che permettono di individuare in anticipo eventuali guasti e anomalie e ottimizzare gli interventi di manutenzione. Un ruolo complementare è svolto dal servizio telematico OnStar, un servizio di connettività che fornisce in tempo reale aggiornamenti e rileva l'eventuale presenza di problemi avvisando in anticipo il conducente di un potenziale guasto. In particolare, il sistema si collega alla connessione Internet 4G LTE di bordo del veicolo per trasmettere dati che saranno elaborati dai server OnStar, dove gli algoritmi determinano se un guasto di un componente è imminente.

Per la gestione delle flotte commerciali, è presente la piattaforma Onstar Business che analizza i dati raccolti per generare i report, identificare i trend di usura abilitando la manutenzione predittiva per l'intera flotta [80-83].

#### **4.5.6 Toyota**

In netto contrasto con le strategie di altri produttori automobilistici, Toyota basa prevalentemente la propria filosofia di manutenzione veicolare su intervalli programmati e piani di tagliando prestabiliti. Attualmente, i veicoli di serie non sono dotati di un sistema intelligente basato sull'elaborazione dei sensori della centralina in grado di modificare dinamicamente gli intervalli di manutenzione. Il sistema si affida invece a tabelle convenzionali, definite centralmente dalla casa madre, che stabiliscono scadenze fisse basate su parametri quali tempo e chilometraggio.

La divisione Toyota Connected sta tuttavia compiendo investimenti significativi nella ricerca e sviluppo di modelli di manutenzione predittiva fondati sull'analisi di big data e sull'intelligenza artificiale. Nell'ambito della manutenzione predittiva, la divisione Toyota Motor North America ha sviluppato un sistema di sensori IoT in collaborazione con la piattaforma Amazon Web Services (AWS), con lo scopo di monitorare in tempo reale lo stato di salute delle macchine utensili. Nel campo della telematica a bordo Toyota ha fondato nel 2016 in partnership con Microsoft la Toyota Connected North America (TCNA), che si occupa di studiare le tecnologie per i servizi di bordo, la telematica e le applicazioni di intelligenza artificiale. Essa processa i dati con lo scopo di sviluppare modelli computazionali che possano prevedere l'usura dei componenti meccanici [84,85].

#### **4.5.7 Stellantis**

La strategia di manutenzione predittiva di Stellantis è integrata nel programma World Class Manufacturing (WCM), che ha lo scopo di aumentare l'efficienza degli impianti attraverso l'eliminazione degli sprechi e il raggiungimento di elevati standard qualitativi. Tuttavia, l'implementazione di reti neurali artificiali e algoritmi di machine learning in questo programma riguarda principalmente il monitoraggio della qualità della produzione e dello stato dei macchinari industriali.

Nell'ambito della mobilità connessa invece, Stellantis ha istituito Mobilisights, divisione specializzata nella gestione delle flotte aziendali che consente un accesso esclusivo ai dati dei veicoli connessi in tempo reale degli OEM a marchio Stellantis. La piattaforma di riferimento Fleet Management Data Pack permette un accesso completo alle informazioni dei veicoli senza costi legati all'installazione di dispositivi aggiuntivi di terze parti.

L'acquisizione della piattaforma CloudMade ha consentito l'implementazione di funzionalità avanzate di diagnosi predittiva e la personalizzazione dell'esperienza di guida. Il framework IA di CloudMade rappresenta un punto di riferimento nel settore per la raccolta e l'analisi di set di dati automobilistici e sarà parte integrante del progetto di Stellantis per migliorare la manutenzione e diagnostica predittiva. Sul fronte tecnologico, gli aggiornamenti dei sistemi di diagnostica remota avverranno over-the-air: grazie a questa tecnologia i conducenti potranno ricevere gli aggiornamenti software necessari a garantire il monitoraggio costante delle condizioni veicolari e la risoluzione di eventuali problematiche a distanza [86-88].

Tabella 6 - Riepilogo di come le case operino nel campo della manutenzione predittiva.

Casa/Gruppo automobilistico	Manutenzione predittiva	Diagnostica	Piattaforme esterne
Gruppo Volkswagen	<p><b>CARIAD</b>, la divisione software del Gruppo Volkswagen, ha sviluppato un sistema di manutenzione predittiva con algoritmi di machine learning per analizzare i dati raccolti dai sensori.</p> <p><b>Piattaforma Digitale di Produzione con AWS</b> rappresenta l'infrastruttura centralizzata per sviluppare e distribuire rapidamente applicazioni basate su machine learning</p> <p><b>Fleet Interface Data</b> è la soluzione "Data-as-a-Service" (DaaS) per la gestione delle flotte.</p>	<p><b>ODIS</b> è il sistema diagnostico ufficiale e proprietario di Volkswagen, che permette di accedere a tutti i sistemi elettronici del veicolo, eseguire letture dei codici errore, coding, adattamenti, aggiornamenti software e procedure guidate di riparazione.</p> <p><b>Sound Analyser</b> è un sistema di diagnostica acustica con AI in grado di registrare i suoni emessi da un veicolo in funzione e confrontarli con quelli di riferimento.</p>	<p><b>AWS (Amazon Web services)</b> sviluppa algoritmi proprietari integrati nella Digital Production Platform (DPP).</p> <p><b>Geotab e Targa Telematics</b> hanno integrato i dati telematici dei veicoli del Gruppo Volkswagen nelle loro piattaforme, offrendo soluzioni complete per la gestione delle flotte.</p>
BMW	<p><b>Condition Based Service (CBS)</b> è il sistema di manutenzione intelligente che monitora vari elementi del veicolo per pianificare i tagliandi. Utilizza sensori con lo scopo di misurare direttamente lo stato di determinati componenti.</p> <p><b>BMW Teleservices</b> si occupa di trasmissione automatica dei dati di manutenzione al centro assistenza BMW</p> <p><b>BMW ISTA (Integrated Service Technical Application)</b> è il software principale del produttore per la diagnostica, la programmazione e la gestione delle centraline.</p>	<p><b>Il modulo DSC (Dynamic Stability Control)</b> calcola l'usura in base a parametri come velocità, pressione di frenata e frequenza delle frenate.</p> <p>Il sistema <b>Teleservices Battery Guard</b> monitora la tensione della batteria e avvisa sia il cliente che il centro assistenza se scende sotto una soglia critica.</p>	<p><b>Microsoft</b>, in qualità di fornitore leader mondiale di tecnologia e partner di lunga data di BMW, fornisce servizi e soluzioni IoT completi, tra cui la manutenzione predittiva tramite Microsoft Azure, il servizio Cloud intelligente.</p>
Mercedes	<p>Mercedes-Benz sta trasformando il suo approccio a manutenzione e connettività dei veicoli attraverso lo sviluppo di un <b>sistema operativo proprietario MB.OS</b>. Si sfrutta la potenza dell'IA per passare dalla manutenzione reattiva a quella predittiva. Integrando l'IA nei propri veicoli, Mercedes-Benz consente al sistema di monitorare lo stato in tempo reale di vari componenti. Mercedes impiega il sistema <b>Active Service System</b> per memorizzare lo storico delle manutenzioni.</p> <p><b>Mercedes PRO Portal</b> è il pannello di controllo online per i fleet manager, che permette di gestire i veicoli, gli utenti e i servizi.</p>	<p><b>Xentry</b> è il sistema diagnostico ufficiale Mercedes-Benz, progettato per interfacciarsi con le centraline (ECU) dei veicoli. <b>XENTRY Remote Diagnosis</b> è l'app web per diagnosi remota che permette di accedere ai dati diagnostici e ai codici di errore dei veicoli Mercedes-Benz da dispositivo mobile.</p> <p><b>Mercedes me Connect</b> è il sistema Mercedes che permette la diagnosi remota del veicolo. In caso di malfunzionamento o incidente, l'auto invia automaticamente dati sullo stato dei sistemi al centro assistenza Mercedes.</p>	<p>Mercedes-Benz utilizza la piattaforma <b>MO360</b>, che raccoglie dati in tempo reale dai veicoli e dai processi produttivi con l'utilizzo di sensori IoT. I veicoli Mercedes-Benz con hardware telematico di fabbrica possono condividere i loro dati nativi (autorizzati da Mercedes-Benz Connectivity Services) direttamente con la piattaforma <b>MyGeotab</b>.</p> <p><b>Microsoft Azure</b>: Piattaforma Cloud per l'elaborazione dei dati e i servizi connessi.</p>

<b>Ford</b>	<b>Il Ford Intelligent Oil-Life Monitor</b> è un sistema che calcola gli intervalli di cambio olio in base all'uso effettivo del veicolo, anziché seguire intervalli fissi.	<b>Sail Diag Ford F1</b> è lo strumento diagnostico che utilizza l'intelligenza artificiale per eseguire operazioni a livello di servizio autorizzato, come la lettura e ripristino dei codici di errore, test dei componenti, adattamento e calibrazione.	Ford collabora con <b>Kortical</b> per applicare algoritmi di machine learning ai dati telematici, inclusi i DTC (Diagnostic Trouble Codes).
<b>General Motors</b>	I veicoli sono equipaggiati con un <b>Oil Life Monitor</b> gestito via computer di bordo. Secondo le istruzioni GMC, il sistema sfrutta dati come ore di funzionamento, giri motore, temperature e carico per stimare l'usura dell'olio. Parallelamente al sistema Oil Life, GM offre la possibilità di monitorare lo stato del veicolo via telematica con la piattaforma <b>OnStar</b> . I dati provenienti dai veicoli possono essere integrati in piattaforme di gestione flotte (anche <b>OnStar business</b> ).	La Manutenzione predittiva è basata su <b>IA</b> : sensori e algoritmi predittivi usati per monitorare i veicoli e prevenire potenziali guasti.	Piattaforma di Digital Twin con <b>NVIDIA</b> sfrutta i digital twins e piattaforme come NVIDIA Omniverse per simulare e ottimizzare principalmente i processi produttivi, come i controlli qualità.
<b>Toyota</b>	<b>Toyota Connected</b> sviluppa modelli di manutenzione predittiva analizzando milioni di vetture connesse. Tuttavia, queste soluzioni sono in fase di ricerca avanzata, poiché non risultano oggi applicazione di questi modelli sulle auto Toyota che sono basate oggi su Time-Based Maintenance.	Usati sistemi diagnostici consolidati come <b>Techstream</b> . La transizione verso diagnosi supportate da AI è in corso ma non ancora dichiarata come elemento centrale della strategia. <b>Digital Twin</b> sono utilizzate per la rilevazione di guasti negli impianti di produzione.	Toyota Motor North America ha adottato un sistema IoT basato su Amazon Web Services (AWS), con servizi come <b>AWS IoT SiteWise</b> e <b>Amazon Lookout for Equipment</b> , per raccogliere dati dai sensori in tempo reale.
<b>Stellantis</b>	La strategia di manutenzione predittiva è integrata nel programma <b>World Class Manufacturing (WCM)</b> . <b>Mobilisights</b> è la divisione "Data as a Service" fornisce i dati telematici in tempo reale per la gestione predittiva delle flotte. <b>Free2move</b> offre servizi di manutenzione preventiva per veicoli commerciali, inclusi avvisi in tempo reale, report di manutenzione e prenotazioni di servizi post-vendita.	Il monitoraggio dello stato diagnostico del veicolo e l'invio di aggiornamenti software avvengono <b>OTA</b> .	<b>CloudMade</b> è una piattaforma Cloud acquisita da Stellantis, che consente diagnosi predittive ed esperienze personalizzate all'interno del veicolo.

## CAPITOLO 5 - CASO STUDIO

Dopo aver approfondito il tema delle manutenzioni, in questo capitolo si delinea il contesto in cui è stato sviluppato il caso studio, esaminando come il nuovo progetto **Performance Durability Rating (PDR)** si sviluppa e si evolve rispetto al precedente algoritmo di **Percentuale di Durata Residua (PdR)**. In particolare, vengono esposte le differenze tra i due approcci, sottolineando come il nuovo modello possa risultare utile per più soggetti in vari ambiti: dai guidatori alle compagnie assicuratrici, passando per i gestori delle flotte fino ai governatori regionali per la limitazione delle circolazioni dei veicoli più inquinanti (aspetto che sarà poi approfondito nel capitolo 7). In seguito, sarà illustrato come i dati dei veicoli in tempo reale siano raccolti e registrati tramite il dispositivo OBD-II e l'interfaccia CAN per poi concludere analizzando il dataset di dati sintetici utilizzati per la realizzazione del modello predittivo.

### 5.1 PDR: le differenze tra vecchio e nuovo approccio

Il progetto Performance Durability Rating (PDR) nasce dal brevetto n° 10201900002209, sviluppato da Ercole Messina, che si concentra su un algoritmo capace di calcolare la Percentuale di Durata Residua (PdR): questo sistema aveva lo scopo di stimare la vita utile rimanente di un'automobile e di alcuni suoi componenti basandosi su quattro parametri: chilometraggio, età, modello e marca del veicolo. Il vecchio PdR si focalizzava sulla probabilità che un'auto potesse continuare a funzionare senza guasti significativi sulla base esclusivamente di quei parametri. L'algoritmo Percentuale di Durata Residua è attualmente integrato nella piattaforma digitale EASYDRIVE, utilizzata per la valutazione dei veicoli usati gestiti da Mobility Village SpA (MO.VI. SpA).

Il nuovo PDR ha lo scopo di assegnare i punteggi a diverse tipologie di performance riguardanti:

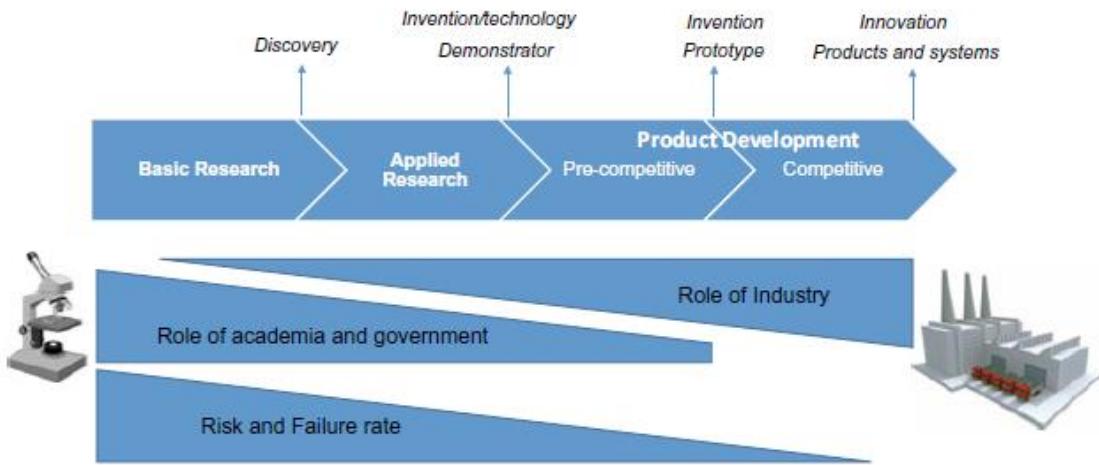
- l'obsolescenza del veicolo;
- impatto ambientale del veicolo;
- rating di affidabilità finalizzato all'utilizzo;
- sicurezza;

- redazione della dichiarazione di conformità (di terza parte) di un veicolo usato.

Il PDR non si distacca dai piani manutentivi time based (TBM, capitolo 3), bensì si integra in modo funzionale a un piano manutentivo programmato, adattandosi alle manutenzioni previste dal costruttore OEM. Un'altra fonte di distacco rispetto al vecchio PdR riguarda il veicolo, inteso come insieme di componenti o sottoinsiemi: infatti il nuovo algoritmo deve essere in grado di riconoscere i problemi non solo a livello di sistema ma anche a livello di componenti, con lo scopo di individuare tra questi ultimi quali sostituire. Come già accennato nel Capitolo 1, il nuovo PDR potrà essere uno strumento di trasparenza e accompagnamento per i clienti nella scelta tra un veicolo prossimo alla fine del suo ciclo di funzionamento e l'acquisto di un veicolo più recente in termini di immatricolazione. Un punto fondamentale del nuovo rating è l'accessibilità: tramite la realizzazione di un'applicazione dedicata, sarà possibile avere sia per gli automobilisti sia per le autorità incaricate una visibilità costante e aggiornata delle condizioni dei veicoli, con diverse priorità di accesso: ogni utente, in base al proprio ruolo (automobilista, forze dell'ordine, enti preposti, ...), potrà consultare informazioni personalizzate e rilevanti per le proprie esigenze operative.

Essendo il PDR uno strumento che ha la finalità di essere versatile, l'algoritmo deve essere sufficientemente flessibile, al fine di poter adattarsi a diversi fattori (dai parametri di utilizzo passando per quelli di spostamento fino alla classe di omologazione) e fornire una valutazione pertinente a ogni contesto analizzato. Un punto importante riguarda l'omologazione alle norme regionali, diverse in termini di mobilità: Il PDR può diventare uno strumento capace di adattarsi alle diverse politiche regionali di circolazione fino ad arrivare alle specifiche esigenze locali.

La robustezza dell'algoritmo nasce anche dalla doppia validazione derivante dalla collaborazione tra l'industria (MO.VI) e l'accademia (Politecnico di Torino). Infatti, da una parte vi sono solide basi tecnico-scientifiche sviluppate su metodologie e modelli matematici che forniranno risultati e risponderanno alle esigenze pratiche dell'altra parte, ossia il settore industriale. I due agenti dell'innovazione (distanti nel classico percorso innovativo previsto dal modello lineare dell'innovazione rappresentato in Figura 12) si incontrano sin da subito per lo sviluppo sia pratico sia teorico del nuovo PDR.



*Figura 12 – Modello lineare di innovazione dal manuale “Management of Innovation and Product Development” [89].*

L'uso di modelli previsionali avanzati basati sull'intelligenza artificiale per il rating dei componenti e dell'intero sistema veicolare consente di stimare con precisione i consumi energetici, individuando le inefficienze. Inoltre, l'ottimizzazione dell'uso di componenti o veicoli ancora funzionanti permette di evitare sostituzioni o dismissioni premature. Un approccio di questo tipo è fondamentale per dare una risposta a un'esigenza sempre più pressante di ridurre al minimo lo spreco delle risorse.

Grazie al nuovo PDR, le aziende possono implementare strategie di manutenzione predittiva delle flotte, tramite l'utilizzo di dati in tempo reale sulle condizioni dei veicoli. Inoltre, sarà possibile avere a disposizione una stima sempre aggiornata del rating del veicolo in circolazione, che costituirà una base per una valutazione economica trasparente. Infine, anche per le compagnie assicurative, il PDR costituirà un importante strumento di valutazione per determinare il livello di garanzia e il costo della polizza associato: coperture assicurative personalizzate e trasparenti, supportate da dati concreti e verificabili, garantiranno agli automobilisti una protezione affidabile contro i guasti e i costi improvvisi.

## 5.2 OBD-II

**OBD (On Board Diagnostic)** è un sistema elettronico presente sugli autoveicoli che permette la segnalazione dei guasti e anomalie, permettendo di monitorare le prestazioni con lo scopo di identificare i guasti in modo tempestivo. L'OBD raccoglie informazioni grazie

alla rete di sensori presenti all'interno del veicolo e determina i connettori e i codici di errore utilizzati, consentendo ai tecnici di effettuare interventi manutentivi mirati.

Le origini del sistema OBD risalgono nei primi anni '80, in cui la necessità di monitorare e ridurre le emissioni di CO<sub>2</sub> da parte delle autovetture spinse verso l'implementazione di un sistema diagnostico on board. Questa necessità divenne realtà negli Stati Uniti grazie al Clean Air Act, che rese obbligatorio l'OBD-II per tutti gli autoveicoli prodotti dal 1996, con lo scopo di monitorare e ridurre le emissioni di CO<sub>2</sub>. In Europa, la Direttiva 98/69/CE ha reso obbligatorio l'equivalente EOBD (European On-Board Diagnostics) dal 2001 per i veicoli a benzina e dal 2004 per quelli diesel [90]. Un punto fondamentale che ha spinto la diffusione dell'OBD riguarda la componente elettronica divenuta dagli anni '80 in poi sempre più diffusa, aumentando la necessità di sistemi di monitoraggio. La struttura del sistema OBD è formata dai seguenti componenti:

- **ECU (Electronic Control Unit)** - unità di controllo del motore, ossia un computer di bordo che elabora e interpreta i dati in tempo reale inviati dalla rete di sensori distribuiti sul veicolo. La funzione della ECU è la gestione dei parametri di funzionamento del motore al fine di garantirne l'efficienza e contenere le emissioni inquinanti entro i limiti di legge. Nel caso in cui i dati ricevuti da un sensore deviano oltre una soglia prestabilita, l'ECU identifica un malfunzionamento, ne registra il codice e decide se allertare il conducente.
- **Sensori** - componenti elettronici installati in posizioni strategiche del veicolo, dedicati al rilevamento e alla misurazione continua di determinati parametri fisici. I dati acquisiti vengono successivamente trasmessi alle ECU sotto forma di segnali elettrici per l'elaborazione.
- **DTC (Diagnostic Trouble Code)** - codice alfanumerico standardizzato che rappresenta l'origine e la natura di un problema rilevato. Infatti, l'ECU, dopo aver rilevato un malfunzionamento, memorizza le informazioni come DTC nel suo archivio. Questi codici sono solitamente standardizzati, ma possono essere specifici del produttore. I DTC, la cui struttura è esposta nella Tabella 7, sono essenziali per indirizzare in modo rapido e accurato la risoluzione dei problemi.

Tabella 7 – Schema di composizione dei codici di guasto DTC.

Carattere	Significato	Valori Comuni e Loro Significato
Primo (lettera)	Sistema del veicolo interessato	P = Powertrain (motore, trasmissione, emissioni) C = Chassis (sterzo, sospensioni, freni) B = Body (componenti dell'abitacolo) U = Network (sistemi di comunicazione del veicolo)
Secondo (numero)	Tipo di codice	0 = Codice generico (standard SAE/ISO) 1 = Codice specifico del costruttore
Terzo (numero)	Sottosistema specifico	0/1/2: Misurazione carburante/aria 3: Sistema di accensione o misfire 4: Controlli ausiliari delle emissioni 5: Controllo velocità e minimo 6: Circuiti computerizzati 7/8/9: Trasmissione A/B/C: Propulsione ibrida
Quarto e Quinto (numero)	Codice specifico del guasto	Identifica il guasto esatto all'interno del sottosistema

- **MIL** - la lampada indicatrice di malfunzionamento, comunemente nota come "spia motore", rappresenta l'interfaccia di allerta diretta con il conducente. Le spie MIL forniscono un sistema di allerta precoce per i malfunzionamenti del veicolo.
- **DLC** - connettore fisico attraverso il quale si accede ai sistemi diagnostici del veicolo. Tramite questo connettore standard si ha accesso a tutti i dati e i codici di guasto che la centralina elettronica ha memorizzato. La porta DLC è il punto di accesso universale per i veicoli equipaggiati con sistemi OBD. Le moderne automobili dispongono di interfaccia OBD-II standard e risultano quindi compatibili con tutti gli scanner che presentano un connettore standard di tipo II. Questo connettore standard a 16 pin (J1962) consente la comunicazione tra il veicolo e le apparecchiature di diagnostica.

Nel corso degli anni il sistema OBD si è evoluto: nei primi anni '80 il sistema avvisava l'utente della presenza di un problema, senza memorizzare alcuna informazione riguardante la

natura di quest'ultimo. I primi sistemi OBD erano di natura proprietaria, quindi differivano tra i produttori delle singole case automobilistiche OEM. Prima del 1990 i codici, i sistemi e le informazioni raccolti da ciascun sistema OBD variavano notevolmente da produttore a produttore. I tecnici, di conseguenza, dovevano disporre dell'attrezzatura per ogni marca di veicolo e spesso gli utenti erano costretti a rivolgersi direttamente alle concessionarie per la diagnosi dei problemi. Nel 1991 un primo importante passo verso l'uniformazione dei sistemi OEM fu il California Air Resources Board che rese obbligatoria la compatibilità OBD su tutte le auto. Tuttavia, questo atto legislativo non aveva emesso nessuno standard per i sistemi OBD, complicando la vita di produttori e clienti. Nel 1994, in risposta a questa esigenza, sono stati emessi diversi standard per i sistemi OBD per tutti i veicoli venduti in California. La Society of Automotive Engineers e l'International Standardization Organization, nota rispettivamente come SAE e ISO, hanno emesso standard su come le informazioni digitali dovrebbero essere scambiate tra ECU e uno strumento di scansione diagnostica. I moderni sistemi OBD utilizzano DLC standardizzati chiamati connettori di tipo 2. Questo consente ai tecnici di utilizzare lo stesso cavo, un cavo di tipo 2, per accedere alle comunicazioni digitali memorizzate nel sistema OBD tramite una porta.

L'Agenzia statunitense per la protezione dell'ambiente EPA (Environmental Protection Agency) richiede che i sistemi OBD monitorino tutti i fattori che possano influire sulle emissioni dei veicoli. Negli anni le applicazioni dei sistemi OBD hanno subito un processo di evoluzione funzionale, non limitandosi esclusivamente al monitoraggio delle emissioni ma espandendosi verso ambiti di manutenzione veicolare più specializzati.

L'esempio più significativo riguarda il monitoraggio del comportamento dei conducenti. Ad esempio, i fornitori assicurativi hanno polizze che offrono premi che condividono i dati di guida raccolti con data logger collegati alle porte OBD e dimostrano di adottare pratiche di guida sicure. Anche le flotte aziendali possono monitorare il comportamento dei conducenti per comprendere appieno le responsabilità in caso di incidente. Il sistema OBD permette anche di accedere a parametri operativi che normalmente non vengono visualizzati nei veicoli standard. Un utilizzo di fondamentale importanza del sistema OBD si ha nelle aziende di veicoli commerciali per raccogliere informazioni sulla propria flotta, che permettono di offrire diversi servizi telematici [91, 92].

### **5.3 Gli standard legati al sistema OBD-II e la comunicazione con ECU**

Come citato nel paragrafo precedente, vi sono degli standard che regolano lo scambio tra ECU e gli strumenti diagnostici. Il sistema OBD-II poggia su un insieme di standard SAE e ISO che definiscono connettori, protocolli di comunicazione e servizi diagnostici.

Il SAE J1979 è uno standard fondamentale sviluppato dalla Society of Automotive Engineers (SAE) che definisce il protocollo di comunicazione per l'accesso ai dati diagnostici relativi alle emissioni dai veicoli. Esso fornisce un metodo standardizzato e universale che consente di elaborare i dati diagnostici dalle ECU (Electronic Control Unit) di un veicolo. Lo scopo ultimo di questo standard è garantire che ogni strumento di scansione idoneo (indipendentemente dal produttore) possa comunicare con qualsiasi veicolo. Lo standard J1979 si appoggia su diversi protocolli veicolari:

- SAE J1850 PWM (Pulse Width Modulation) - utilizzato principalmente da Ford e Chrysler, ha una velocità di trasmissione di 41.6 kbps e richiede due cavi per la comunicazione bidirezionale.
- ISO 14230-4 KWP2000 (Keyword Protocol 2000) - standardizzato per molti veicoli asiatici ed europei, supporta velocità più elevate ed è progettato per gestire una comunicazione più efficiente tra ECU e scanner diagnostici.
- ISO 15765-4 CAN-Bus - lo standard più diffuso oggi, obbligatorio per tutti i veicoli prodotti dal 2008 in poi. Supporta velocità fino a 1 Mbps, permettendo una comunicazione più veloce e affidabile tra i sistemi del veicolo [93].

Il J1979 organizza la comunicazione diagnostica (Tabella 8) attraverso Servizi e Parameter IDs (PID).

- Servizi (Modi): sono funzioni diagnostiche principali. Lo standard originale definisce 10 servizi (da \$01 a \$0A in esadecimale).
- Parameter IDs (PID): sono codici che identificano specifici parametri o dati all'interno di un servizio.

*Tabella 8 - Descrizione dei servizi dello standard J1979.*

Servizio (esadecimale)	Descrizione
\$01	Mostra i dati attuali
\$02	Mostra i dati del fermo immagine
\$03	Mostra i codici di errore diagnostici memorizzati
\$04	Cancella i codici di errore diagnostici e i valori memorizzati
\$05	Risultati dei test, monitoraggio del sensore di ossigeno (solo non CAN)
\$06	Risultati dei test, monitoraggio di altri componenti/sistemi
\$07	Mostra i codici di errore diagnostici in sospeso (rilevati durante il ciclo di guida corrente o precedente)
\$08	Controllare il funzionamento del componente/sistema di bordo
\$09	Richiedi informazioni sul veicolo
\$0A	Codici di errore diagnostici permanenti (DTC)

Con l'aumentare della complessità dei veicoli le limitazioni del J1979 classico, in particolare lo spazio limitato per i codici di guasto (DTC a 2 byte) e i dati di contesto insufficienti, hanno reso necessaria un'evoluzione: lo standard SAE J1979-2 si appoggia internamente ai servizi dell'ISO 14229-1 (UDS - Unified Diagnostic Services), un protocollo diagnostico più ricco e flessibile già ampiamente utilizzato per la diagnostica avanzata dei costruttori. Tra le migliorie apportate vi è l'utilizzo di DTC estesi a 3 byte e la fornitura di Extended Data Records, che forniscono un contesto molto più dettagliato sui guasti occorsi. Lo standard SAE J1979-2 è diventato obbligatorio negli Stati Uniti nel 2023 e lo sarà per tutti i veicoli con motori a combustione a partire dal 2027 [94, 95].

Lo standard ISO 15031-5 stabilisce che i dispositivi esterni (tra cui lo scanner) possono interagire con l'ECU per ricevere dati utili alla diagnosi delle emissioni. Si rifà inoltre allo standard SAE J1979 per i codici PID, ed è parte di un sistema più ampio (ISO 15031) finalizzato alla diagnostica emissioni. Il suo scopo ultimo è supportare le normative antinquinamento abilitando ispezioni tecniche e manutenzione efficaci. L'ISO 15031-5 è progettato per essere indipendente dal protocollo di trasporto sottostante, ma ne definisce le modalità di utilizzo per i servizi emissioni. Per quanto riguarda i Parameter IDs (PID), lo standard si allinea perfettamente e fa esplicito riferimento allo SAE J1979.

Il Regolamento (CE) n. 715/2007, adottato il 20 giugno 2007, rappresenta un pilastro normativo per l'omologazione dei veicoli endotermici delle categorie M1, M2, N1 e N2 con una massa di riferimento non superiore a 2 610 kg. Sono stabiliti i requisiti tecnici comuni per l'omologazione dei veicoli a motore e dei pezzi di ricambio, tra cui i dispositivi di controllo dell'inquinamento. Vi sono anche norme relative alla conformità in servizio dei dispositivi e dei sistemi diagnostici di bordo (OBD). Il regolamento delibera che i costruttori debbano fornire accesso illimitato e standardizzato alle informazioni per la riparazione e la manutenzione dei veicoli agli operatori indipendenti in egual misura rispetto a quelli autorizzati. Tra queste informazioni che devono essere messe a disposizione vi sono anche i codici di guasto DTC [96].

#### 5.4 CANedge3

Il dispositivo CANedge3 (Figura 13) è un registratore di dati avanzato progettato per acquisire e analizzare informazioni provenienti dai sottosistemi e componenti veicolari attraverso l'interfaccia OBD-II e le reti CAN. Grazie al supporto per il protocollo CAN classico e la più recente evoluzione CAN FD (Flexible Data-rate), il dispositivo garantisce un'elevata compatibilità con le architetture veicolari moderne.



Figura 13 – Dispositivo CANedge3.

Il CANedge3 è dotato di un'interfaccia dual-channel CAN/LIN, che acquisisce i dati simultaneamente da multiple reti veicolari, come il sistema propulsivo, l'impianto frenante ABS e i sistemi di controllo della trazione. I dati acquisiti vengono memorizzati su schede SD industriali rimovibili con capacità fino a 1 TB, utilizzando il formato MDF4, standard

interoperabile che assicura la compatibilità con strumenti open-source e software specialistici come Python e MATLAB.

L'implementazione di interfacce Wi-Fi integrate consente il trasferimento automatico dei dati verso i server Cloud, eliminando la necessità di interventi manuali e garantendo un accesso efficiente alle informazioni. Inoltre, per l'analisi delle dinamiche veicolari, il CANedge3 incorpora un modulo GPS e un'unità IMU (Inertial Measurement Unit), permettendo rispettivamente la registrazione di dati geospaziali (posizione, altitudine) e parametri cinetici (accelerazioni, inclinazioni, rotazioni).

Il dispositivo offre molteplici possibilità di personalizzazione, consentendo agli utenti di configurare parametri operativi specifici come le frequenze di campionamento, l'applicazione di filtri selettivi e l'attivazione di trigger basati su eventi particolari.

Sul fronte della sicurezza informatica, il dispositivo supporta protocolli di cifratura e meccanismi di protezione avanzati, garantendo la riservatezza e l'integrità dei dati registrati. Queste caratteristiche rendono il CANedge3 uno strumento fondamentale per molteplici ambiti applicativi, includendo il monitoraggio di veicoli elettrici e ibridi, la gestione di flotte oltre ad attività di ricerca e sviluppo, contribuendo parallelamente alla promozione della sostenibilità ambientale attraverso l'ottimizzazione delle risorse e la riduzione degli sprechi [93, 97].

## 5.5 Analisi delle variabili OBD e le loro relazioni

Il caso di studio ha lo scopo di porre un primo passo per la realizzazione di un modello predittivo che riesca, partendo dall'analisi di dati in tempo reale, a individuare i valori anomali all'interno di queste variabili e possa associarle a un codice DTC in modo tale da orientare gli interventi manutentivi, che possono consentire di prevenire i guasti e garantire quindi una manutenzione efficiente ed una maggiore sicurezza per il conducente.

I dati in tempo reale per la prima analisi derivano da un dataset sintetico [98] formato da una flotta di 49 veicoli, le cui variabili registrate sono elencate nella Tabella 9. Esse rappresentano un insieme di elementi fisici e diagnostici del veicolo, formando un totale di 40 attributi. Il dataset fornisce per ogni auto un quadro completo, integrando dati di natura meccanica e ambientale, con un totale di 1970 osservazioni.

Tabella 9 – Elenco delle variabili presenti nel dataset.

Variable	Descrizione	Unità di misura
vehicle_id	Identificativo del veicolo	Targa
brand	Marca/modello o casa costruttrice del veicolo	Modello
timestamp	Data e ora della lettura	Datetime
odometer_reading	Contachilometri totale	Km
engine_temp_c	Temperatura motore in gradi Celsius	°C
engine_rpm	Regime motore in giri al minuto	rpm
oil_pressure_psi	Pressione olio motore	psi
coolant_temp_c	Temperatura del liquido di raffreddamento	°C
fuel_level_percent	Percentuale carburante nel serbatoio	%
fuel_consumption_lph	Consumo di carburante	l/h
engine_load_percent	Percentuale di carico del motore	%
throttle_pos_percent	Posizione dell'acceleratore (apertura farfalla)	%
air_flow_rate_gps	Flusso d'aria	g/s
exhaust_gas_temp_c	Temperatura gas di scarico	°C
vibration_level	Livello di vibrazione	adimensionale
engine_hours	Ore totali di funzionamento del motore	h
brake_fluid_level_psi	Livello del fluido freni	psi
brake_pad_wear_mm	Usura delle pastiglie freno	mm
brake_temp_c	Temperatura dei freni	°C
abs_fault_indicator	Indicatore guasto ABS	0=ok 1=guasto
brake_pedal_pos_percent	Pressione nel circuito frenante	%
wheel_speed_fl_kph	Velocità ruota anteriore sinistra	Km/h
wheel_speed_fr_kph	Velocità ruota anteriore destra	Km/h
wheel_speed_rl_kph	Velocità ruota posteriore sinistra	Km/h
wheel_speed_rr_kph	Velocità ruota posteriore destra	Km/h
battery_voltage_v	Tensione batteria in Volt	V
battery_current_a	Corrente batteria in Ampere	A
battery_temp_c	Temperatura batteria	°C
alternator_output_v	Uscita alternatore	V
battery_charge_percent	Percentuale di carica batteria	%
battery_health_percent	Stato di salute batteria	%

vehicle_speed_kph	Velocità del veicolo	Km/h
ambient_temp_c	Temperatura ambiente esterna	°C
humidity_percent	Umidità relativa ambiente	%
gps_latitude	Latitudine GPS	gradi decimali
gps_longitude	Longitudine GPS	gradi decimali
engine_failure_imminent	Flag (0/1) che indica predizione di guasto motore imminente	0=ok 1=guasto
brake_issue_imminent	Flag (0/1) per problema freni imminente	0=ok 1=guasto
battery_issue_imminent	Flag (0/1) per problema batteria imminente	0=ok 1=guasto
failure_date	Data prevista per il guasto	Datetime
failure_type	Etichetta/testo del tipo di guasto previsto	Tipo di guasto

In seguito, è riportata una suddivisione delle variabili in quattro sottosistemi e una breve descrizione delle loro principali relazioni.

### 5.5.1 Sistema di propulsione (motore e carburante)

Una percentuale elevata di apertura dell'acceleratore richiede più potenza, aumentando i giri del motore e, di conseguenza, la velocità del veicolo. Un'accelerazione rapida influenza anche di conseguenza la percentuale di carico del motore. Il consumo di carburante è direttamente proporzionale ai giri del motore e alla percentuale di apertura dell'acceleratore.

Un elevato numero di giri del motore genera calore, che conseguentemente aumenta le temperature dei gas di scarico. Il sistema di raffreddamento, il cui stato è indicato dalla temperatura del liquido di raffreddamento, deve dissipare questo calore. Una temperatura che risulta alta in modo anomalo rispetto a quella del motore può indicare un malfunzionamento.

La pressione dell'olio bassa a regimi di motore elevati può costituire un segnale di allarme. Un aumento anomalo dell'intensità delle vibrazioni può essere un segnale di problemi interni al motore. Infine, le ore di funzionamento rappresentano l'usura cumulativa del motore.

### **5.5.2 Sistema frenante**

L'uso dei freni genera attrito e conseguentemente calore. La temperatura dei freni aumenta durante la frenata, che può essere logicamente dedotta da un calo di velocità del veicolo. L'usura delle pastiglie dei freni è una conseguenza diretta dell'attrito, ed aumenta con l'incremento delle ore di funzionamento del motore. Una pressione sul pedale dei freni con uno scarso effetto frenante può essere premonitore per problemi al fluido o all'impianto idraulico.

### **5.5.3 Sistema elettrico e di accumulo (batteria)**

Lo stato della batteria è indicato dalle variabili legate alla tensione e alla carica della batteria. L'uscita dell'alternatore rappresenta la fonte di ricarica. Quando il motore è in funzione (valore di `engine_rpm > 0`), l'alternatore dovrebbe produrre una tensione superiore a quella della batteria per caricarla. Un valore basso della tensione d'uscita dell'alternatore potrebbe rappresentare un guasto alla batteria. La temperatura della batteria ha un impatto significativo su prestazioni e longevità.

### **5.5.4 Variabili dinamiche, ambientali e di sintesi**

Le variabili legate alla temperatura dell'ambiente esterno e alla percentuale di umidità rappresentano dei fattori esterni che possono influenzare l'efficienza del raffreddamento oppure le prestazioni della batteria. Le variabili binarie sul guasto imminente (rispettivamente di motore, impianto frenante e batteria) sono flag che si attivano nel momento in cui i dati in tempo reale mostrano una deviazione anomala da questi pattern appresi [98].

## CAPITOLO 6 - ANALISI ED ELABORAZIONE DEI DATI DEL CASO STUDIO

In questo capitolo viene esposto il metodo utilizzato per la realizzazione del modello predittivo e i risultati ottenuti [99]. Partendo da una ricerca nella letteratura scientifica sono stati identificati gli algoritmi su cui sviluppare un modello che ha lo scopo di rilevare le anomalie all'interno del dataset analizzato, per poi successivamente stimare la vita utile rimanente dei componenti dei veicoli.

### 6.1 Gli algoritmi di machine learning usati nell'ambito manutentivo

Nella letteratura scientifica sono presenti svariati studi che hanno utilizzato diverse tecniche di machine learning per elaborare i dati in tempo reale dei veicoli al fine di generare dei modelli predittivi per la manutenzione. Nell'articolo “A Review of OBD-II-Based Machine Learning Applications for Sustainable, Efficient, Secure, and Safe Vehicle Driving” gli autori analizzano come il ML elabora i dati OBD, per rendere la diagnostica proattiva con lo scopo di identificare le anomalie e prevedere il livello di degradazione utile per piani di manutenzione condition-Based (CBM). Tra gli algoritmi più utilizzati nell'ambito manutentivo vengono menzionati: Decision Tree (DT), Support Vector Machine (SVM), Random Forest (RF), Gradient Boosting Machine (GBM). Nel campo del deep learning, Recurrent Neural Networks (RNN) e Long Short-Term Memory (LSTM) eccellono nell'apprendimento da dati sensoriali ad alta dimensionalità e temporalmente correlati [24].

Gli **Autoencoder** risultano molto utili nella rilevazione di anomalie poiché sono in grado di apprendere in una prima fase il comportamento normale dei dati e poi successivamente segnalare le deviazioni. Essi sono in grado di svolgere questo compito per ogni gruppo di componenti, risultando degli algoritmi molto flessibili [100].

Le **LSTM** catturano relazioni temporali (dipendenze corte e lunghe) e modellano l'evoluzione della degradazione. Sono ideali per prevedere il ciclo di carica e scarica delle batterie e anche per il degrado dell'impianto frenante poiché questo algoritmo segue i trend di usura. Nell'articolo “A deep learning approach to optimize remaining useful life prediction for Li-ion batteries”, viene spiegato come, sfruttando la potenza combinata di Autoencoder e LSTM, il modello mostra notevoli progressi, in termini di accuratezza ed

efficienza rispetto ai metodi tradizionali, nel calcolo e nella previsione della vita utile rimanente dei componenti [100].

Il **Random Forest** è un algoritmo molto robusto e resistente al rumore ed ha una stabilità migliore rispetto agli alberi singoli. Questo algoritmo risulta molto efficace soprattutto nei casi in cui ci sono pochi campioni etichettati (maggiore robustezza) disponibili.

Le **reti neurali complesse (CNN)** sono algoritmi in grado di modellare le relazioni non lineari tra input e output, come quelle tra corrente, temperatura, resistenza interna. Queste reti neurali eccellono nell'isolare i tratti distintivi da segnali già elaborati, come ad esempio quelli di vibrazione. Per questo trovano un'applicazione perfetta nell'analisi di sistemi rotanti, come il motore dell'autovettura [101].

## 6.2 La rilevazione di anomalie: Autoencoder + Random Forest + normalizzazione

Per rilevare le anomalie all'interno del dataset sintetico, le cui variabili sono elencate nel paragrafo precedente, è stato utilizzato un approccio ibrido che combina l'apprendimento non supervisionato (**Autoencoder**) per l'allerta precoce e l'apprendimento supervisionato (**XGBoost**) per il rilevamento di guasti imminenti. Successivamente le anomalie sono state associate ai codici DTC anche grazie all'utilizzo di un modulo di diagnostica basato su Z-Scores.

La prima fase del codice prevede la pulizia, la copertura di valori mancanti e la normalizzazione del dataset. Successivamente sono state create le feature, ossia le variabili indipendenti che un modello utilizza per effettuare una previsione. In seguito, vi è la **standardizzazione (Z-Scores)**: essa trasforma tutti i dati dei sensori in "Z-Scores", posizionando sostanzialmente ogni valore in relazione alla sua media e deviazione standard, come nella formula seguente. In questo modo la nuova distribuzione sarà una standard normale, caratterizzata da media  $\mu = 0$  e deviazione standard  $\sigma = 1$ .

$$z = \frac{x - \mu}{\sigma} \quad [18]$$

La seconda fase del codice è focalizzata sull'algoritmo di Autoencoder (AE), una rete neurale che, come è già stato descritto nel paragrafo 3.8, impara a comprimere i dati (encoder) per poi successivamente ricostruirli (decoder). La logica di funzionamento di questo algoritmo

è basata sul concetto di **Loss di ricostruzione**, una metrica che misura la differenza quantificata tra l'input originale che è stato fornito all'AE e l'output che l'AE è riuscito a ricostruire. Essa è calcolata come la Media degli Errori Quadratici (Mean Squared Error - MSE):

$$Loss = \frac{1}{N} \sum_{i=1}^N (Input_i - Output_i)^2 \quad [19]$$

Nel momento in cui un dato anomalo (mai elaborato dall'algoritmo) viene analizzato, l'Autoencoder fallisce nel ricostruirlo fedelmente. L'errore di ricostruzione, misurato proprio dalla Loss, rappresenta quindi il segnale di anomalia. Viene calcolata la Loss di ricostruzione per tutti i campioni. Utilizzando la curva **Precision-Recall**, si stabilisce la soglia ottimale che massimizza l'**F1-Score** per definire il confine tra "sano" e "allerta precoce". Ogni Loss che supera questa soglia indica una potenziale deviazione dal comportamento normale.

La curva Precision-Recall mostra la relazione tra Precisione (Precision) e Richiamo (Recall) al variare della soglia di classificazione (la loss di ricostruzione), le cui differenze sono spiegate nella Tabella 10.

*Tabella 10 - Spiegazione della curva precision-recall.*

Metrica	Significato	Commento
<b>Richiamo</b>	La frazione di guasti reali che il modello ha identificato correttamente	È necessario un alto recall per non mancare guasti critici.
<b>Precisione</b>	La frazione di allarmi emessi dal modello che erano effettivamente guasti reali.	È necessaria un'alta precisione per evitare di generare allarmi inutili.

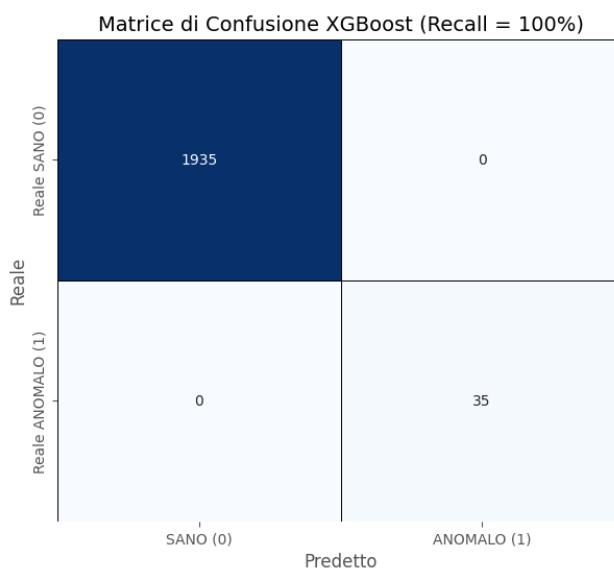
L'obiettivo è trovare un punto sulla curva che offra un equilibrio accettabile tra la soglia molto bassa (alto recall, bassa precisione) e la soglia molto alta (basso recall, alta precisione). L'F1-Score è la media armonica delle due metriche, che assegna un punteggio basso se una delle due metriche è bassa.

$$F1 - Score = 2 \times \frac{Precisione \times Richiamo}{Precisione + Richiamo} \quad [20]$$

La Loss di ricostruzione che produce il massimo F1-Score è considerata la soglia ottimale per l'Autoencoder, poiché rappresenta il miglior compromesso tra l'essere certi che un allarme sia reale (precisione) e l'assicurazione di non mancare nessun guasto (richiamo).

La terza fase prevede l'implementazione di XGBoost, un classificatore specializzato nell'identificazione di guasti imminenti o già manifesti. Questo algoritmo costruisce sequenzialmente alcuni alberi decisionali ed è addestrato sui dati etichettati per prevedere la probabilità che un veicolo sia in uno stato di guasto. Per favorire un bilanciamento delle classi e pesare maggiormente i campioni di guasto che sono rari nel dataset (35 su 1970) si utilizza il parametro `scale_pos_weight`.

Per associare le specifiche variabili anomale al codice di guasto corretto è stato utilizzato un file CSV, in cui ogni codice era associato alla variabile causa dell'anomalia. Partendo da questo, l'algoritmo successivamente crea una mappa prioritizzata, in cui ogni DTC è associato a una soglia Z-score, che ne definisce la priorità diagnostica. Viene scelto il primo nella lista (priorità alta), le cui variabili associate hanno tutte superato la soglia critica definita per quel DTC. La particolarità risiede proprio nell'analisi delle relazioni tra queste variabili e non nella singola anomalia rilevata: il modello analizza tutte le anomalie e le loro relazioni, andando successivamente a formulare il codice DTC più adatto ai dati analizzati. L'efficacia del modello si può esprimere attraverso la matrice di confusione rappresentata in Figura 14:



*Figura 14 – Matrice di confusione del modello che utilizza Autoencoder e XGBoost per la rilevazione di anomalie.*

- **I Veri Negativi (1935)** sono i campioni che erano **realmente sani** e che il modello ha correttamente predetto come **sani**.
- **I Veri Positivi (35)** sono i campioni che erano **realmente anomali** (guasti imminenti) e che il modello ha correttamente predetto come **anomali**.
- **I Falsi Positivi (0)** sono i campioni che erano **realmente sani** ma che il modello ha erroneamente predetto come **anomali** (guasti imminenti).
- **I Falsi Negativi (0)** sono i campioni che erano **realmente anomali** ma che il modello ha erroneamente predetto come **sani**.

Questa rappresentazione identifica un modello che funziona perfettamente, anche a causa delle dimensioni modeste del dataset e dei guasti che si discostano dai valori normali delle variabili. Bisogna comunque tenere in considerazione che i dati sono simulati affinché si possano addestrare questi modelli di predizione.

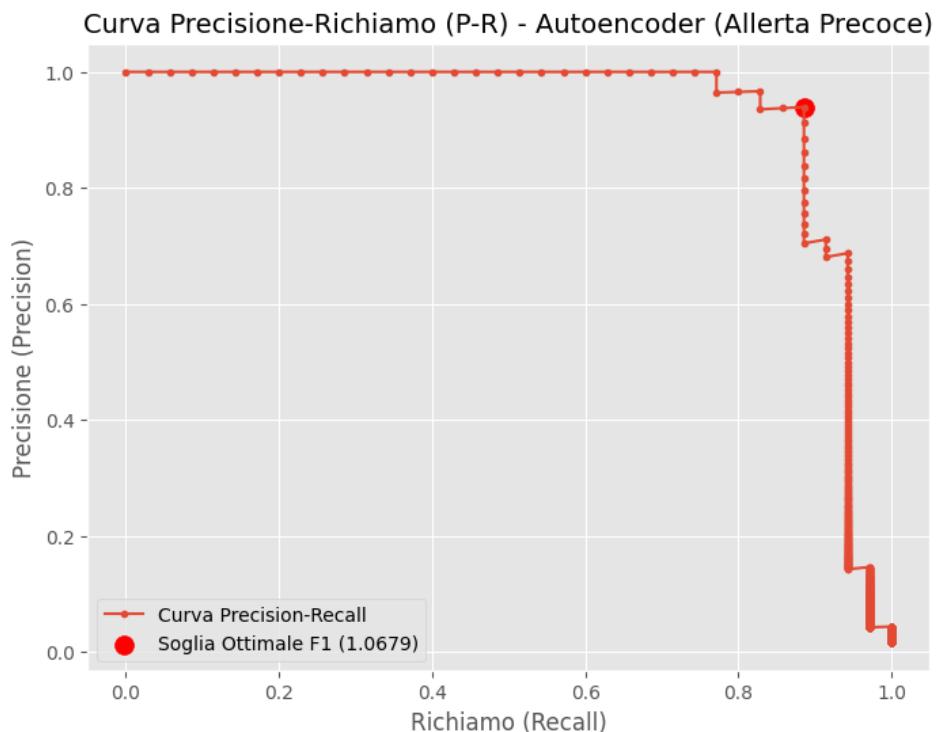


Figura 15 – Curva Precisione-Richiamo.

La solidità è dimostrata anche dalla curva precisione-richiamo (Figura 15), in cui si vede la soglia ottimale: il punto in cui la combinazione di precisione e richiamo massimizza l'F1-score (media armonica tra i due) è pari a 1.0679. Il modello mantiene una precisione molto

alta (vicina a 1.0) per gran parte della curva, che si traduce in una rilevazione quasi perfetta delle anomalie presenti.

Le anomalie rilevate dal codice presenti nell'output hanno la struttura illustrata nella Tabella 11.

*Tabella 11 - Spiegazione output delle anomalie.*

Campo Stampato	Scopo e Fonte del Dato
Anomalia alla riga X	Indica l'indice del dato nel set che è stato classificato come critico
Tipo di Guasto Reale	Etichetta del guasto usata per la validazione
DTC Predetto	Il codice di errore diagnosticato
Descrizione DTC	La spiegazione standard del codice DTC
5 Variabili Contributori	Le 5 variabili che hanno la massima deviazione dalla norma

Per comprendere in modo corretto il lavoro effettuato dal modello, si propone una descrizione della rilevazione di un'anomalia, riportata in Figura 16.

```

--- Anomalia alla riga 446 ---
Tipo di Guasto Reale: Engine Overheat
DTC Predetto: P0300
Descrizione DTC: Random/Multiple cylinder Misfire Detected
Top 5 Variabili Contributori (Deviazione |z|-Score):
- vibration_level: 5.3708
- oil_pressure_psi: 3.6000
- engine_temp_c: 2.4232
- wheel_speed_rl_kph: 1.6502
- gps_longitude: 1.4289

```

*Figura 16 – Esempio di output di un'anomalia rilevata dal modello.*

Innanzitutto, l'intero campione (riga 446) è stato classificato come anomalo poiché la sua probabilità di guasto ha superato la soglia aggressiva. L'associazione al codice DTC P0300 (una mancata accensione causale o multipla del cilindro associata a un guasto del motore) è il risultato dell'analisi di più variabili:

- attraverso la funzione diagnose\_dtc\_zscore si trova un valore di vibration\_level pari a 5,3708 che supera lo Z-score pari a 3, valore soglia necessario per il codice P0300;

- tuttavia, il sistema riconosce che la causa indiretta principale di questa anomalia è il surriscaldamento che, pur non producendo un segnale di Z-score *statisticamente estremo* ( $2,4232 < 3$ ) sulla variabile temperatura, ha causato un livello di vibrazione estremo;
- il valore di pressione dell'olio ha uno Z-score pari a 3.6, che conferma un guasto al motore, dal momento che l'alta vibrazione (causata da surriscaldamento) spesso degrada rapidamente la pressione dell'olio.

Il modello, quindi diagnostica il sintomo più estremo (la vibrazione), ma grazie all'analisi delle variabili e delle loro relazioni, riesce a fornire una chiave di lettura più ampia in ambito manutentivo, non soffermandosi solo sul singolo valore anomalo ma aiutando a risalire alla causa primaria del guasto, nonostante essa possa essere indiretta o nascosta da anomalie maggiori, che rappresentano però una logica conseguenza del malfunzionamento originario.

### **6.3 Il calcolo della RUL con Autoencoder e XGBoost**

Dopo la fase di identificazione delle anomalie, il passaggio successivo risiede nell'associazione dei potenziali guasti al tempo di vita utile del componente. La logica di questa seconda parte si basa sui codici diagnostici di guasto per **stimare la vita utile rimanente** e fornire una diagnosi specifica. Questa associazione rappresenta l'essenza della manutenzione predittiva, che non si ferma alla sola rilevazione del guasto ma ne vuole prevedere anche il momento per intervenire in modo tempestivo. Quindi la diagnostica DTC ha lo scopo di individuare la causa del guasto, mentre la previsione della RUL è necessaria per comprendere quando esso avverrà.

La seconda parte del codice si fonda sempre sull'integrazione tra i modelli Autoencoder e XGBoost. Il primo è addestrato sui dati che presentano un andamento normale, in modo tale da apprendere la struttura dei dati privi di guasto. Nel momento in cui elabora nuovi dati, se la Loss di ricostruzione presenta una deviazione significativa, scatta il segnale di ALLERTA PRECOCE. XGBoost, oltre a prevedere un guasto imminente (con classificazione binaria), produce anche una **probabilità di guasto**. Una soglia ottimale XGB, che massimizza l'F1-score, viene calcolata per determinare se la probabilità è sufficientemente alta per dichiarare lo stato CRITICO. Per riassumere vi è una selezione gerarchica:

- se XGBoost è critico, lo stato è CRITICO;
- se l'Autoencoder rileva un'anomalia, lo stato è ALLERTA PRECOCE;
- se entrambi non rilevano anomalie, lo stato è SANO.

Nel seguente modello la RUL è indicata come stima temporale, espressa in giorni, del tempo rimanente prima che il componente o il veicolo possa subire un guasto. Il modello lavora con due tipologie di RUL: statica e dinamica.

Per **RUL statica** s'intende un valore predeterminato per la pianificazione dell'intervento non regolato direttamente dall'analisi dei dati e riguarda gli stati SANO e ALLERTA PRECOCE. Quando il sistema rileva uno stato SANO, viene definito un valore RUL completamente fittizio, che si traduce sostanzialmente nell'assenza di anomalie e in una vita utile da considerarsi completa. Quando si rileva lo stato di ALLERTA PRECOCE, la RUL è fissata a 30 giorni: una finestra di intervento a medio termine che fornisce un tempo sufficiente per pianificare la manutenzione, basandosi sull'anomalia lieve rilevata dall'Autoencoder. Lo scopo di questa finestra di RUL è prevenire il guasto in modo da evitare che lo stato diventi CRITICO.

Nel momento in cui viene rilevato uno stato CRITICO, il modello elabora una **RUL dinamica**, che sia basata sul modello XGBoost e rispecchi lo stato del componente in modo effettivo e non più approssimativo. Essa è compresa tra 1 giorno (massima urgenza) e 7 giorni (urgenza moderata):

- se la probabilità è appena al di sopra della soglia critica, la RUL è massima (7 giorni).
- se la probabilità è vicina al 100%, la RUL si riduce rapidamente verso il minimo (1 giorno).

È necessario effettuare una precisazione sul contesto temporale. Questo modello elabora le anomalie efficacemente e anche il calcolo della RUL è fondato sull'analisi di quest'ultime. Tuttavia, i riferimenti temporali sono indicativi per il modello poiché, a fianco ai dati in tempo reale, non vi sono i dati storici di manutenzione, gli interventi effettuati e i chilometraggi percorsi dalle autovetture. Queste misure permetterebbero al modello di elaborare un contesto temporale e rendere il calcolo della RUL adatto al campo operativo in cui è inserito. Dal momento che gli intervalli temporali rispecchiano lo stato dei componenti, ma i loro riferimenti sono approssimativi, il modello affianca alla RUL una

misura percentuale definita **OMI (Overall Maintenance Index)**: un indice di salute oggettivo che fornisce una valutazione immediata dello stato del veicolo. L'OMI è progettato per essere completamente dinamico su tutto il suo spettro, agendo in modo inversamente proporzionale al rischio di guasto. Questo indice, come per la RUL si adatta allo stato del veicolo:

- nello stato SANO, l'OMI è fisso al 100 % e indica l'assenza di anomalie;
- nello stato ALLERTA PRECOCE, l'OMI assume un valore compreso tra il 40% e 100% e si basa sull'andamento della Loss di ricostruzione; all'aumentare della Loss l'OMI diminuisce, fino al momento in cui l'anomalia è prossima allo stato CRITICO;
- nello stato CRITICO, il valore dell'OMI varia tra il 40 % e lo 0 % ed è inversamente proporzionale alla Probabilità di Guasto; maggiormente l'XGBoost considera il guasto imminente, più l'OMI crolla verso lo zero, fornendo un riflesso immediato della salute in deterioramento che è perfettamente allineato all'accorciamento della RUL.

L'OMI è un indice che permetterà al modello di calcolare una RUL più precisa, adattandosi allo storico temporale e chilometrico delle auto fornendo un intervallo di soglia adatto al caso analizzato.

L'output fornito dal modello (Figura 17) documenta il successo dell'addestramento e i risultati del modello ibrido. In un primo report, si forniscono le metriche utilizzate e i 36 guasti rilevati, di cui un falso negativo.

REPORT A: DETTAGLIO DI TUTTE LE LETTURE IN STATO DI ALLERTA (CRITICO e PRECOCE)							
Veicoli con Guasto Imminente (RUL < 60gg): 25							
Numero Totale di Letture (Nighe) in Stato ALLERTA Predetto: 36							
Soglia XGB (Probabilità Minima per CRITICO): 0.9978   Soglia AE (Loss Minima per ALLERTA): 1.1059							
TIPPO ALLARME	VEHICLE_ID	RUL Pred. (Giorni)	OMI (%)	Probabilità Anomalia (%)	RUL Reale (Giorni)	Guasto Reale	DTC Code   DTC Descrizione
CRITICO VERO	VEH0026	1.96	6.41	99.95	4.00	Low Brake Fluid   C1015	Brake Fluid Level Sensor Circuit Low
CRITICO VERO	VEH0004	2.24	8.29	99.94	2.00	Low Brake Fluid   C1015	Brake Fluid Level Sensor Circuit Low
CRITICO VERO	VEH0035	2.25	8.33	99.94	1.00	Low Brake Fluid   C0284	Brake Overheat Condition
CRITICO VERO	VEH0026	2.29	8.57	99.94	4.00	Brake Pad Worn   C0284	Brake Overheat Condition

Figura 17 – Prima parte dell'output del modello con le anomalie rilevate.

Sono inoltre specificate le soglie che sono state utilizzate per classificare le anomalie.

- Soglia XGB (Probabilità Minima per CRITICO): se la probabilità di anomalia supera il 99,70 %, lo stato classificato è CRITICO;

- Soglia AE (Loss Minima per ALLERTA): 1.1059 è il valore minimo di ricostruzione per cui l'Autoencoder rileva un'anomalia per avviare lo stato di ALLERTA.

Il secondo report (Figura 18) aggrega i risultati del modello per ogni veicolo e li suddivide per i tre sistemi principali: motore, freni e batteria.

Totale Veicoli Analizzati: 50		
Veicoli con urgenza CRITICA: 25		
Veicoli con urgenza ALLERTA PRECOCE: 0		
VEHICLE_ID   Tipo Guasto Reale (Storico)	Motore Status (RUL/OMI/OTC)	Freni Status (RUL/OMI/OTC)
VEH0004   Low Brake Fluid	SANO (RUL SANO / OMI 100.00%)	CRITICO (RUL 2.24 dB / OMI 8.29% / C1015)
VEH0005   Low Brake Fluid	SANO (RUL SANO / OMI 100.00%)	CRITICO (RUL 2.53 dB / OMI 10.22% / C0284)
VEH0006   Battery Dead	SANO (RUL SANO / OMI 100.00%)	SANO (RUL SANO / OMI 100.00%)
VEH0008   Brake Pad Worn	SANO (RUL SANO / OMI 100.00%)	CRITICO (RUL 2.55 dB / OMI 10.31% / C0284)
VEH0009   Brake Pad Worn	SANO (RUL SANO / OMI 100.00%)	CRITICO (RUL 2.30 dB / OMI 8.67% / C0284)

Figura 18 – Seconda parte dell'output del modello con un'analisi delle anomalie raggruppate per veicolo.

Lo stato CRITICO indica che per quel gruppo di componenti, il modello ha previsto un guasto imminente (RUL bassa) con alta certezza e richiede un intervento immediato. Lo stato SANO è determinato dall'assenza di anomalie significative rilevate in quel gruppo di componenti. I risultati del report sono riassunti dal grafico rappresentato in Figura 19, che rappresenta la distribuzione degli stati di allerta rilevati dal modello ibrido Autoencoder + XGBoost sui principali sistemi veicolari. Dall'analisi emerge che il sistema frenante risulta maggiormente soggetto ad allarmi, mentre il motore presenta un numero minore ma più critico di segnalazioni.

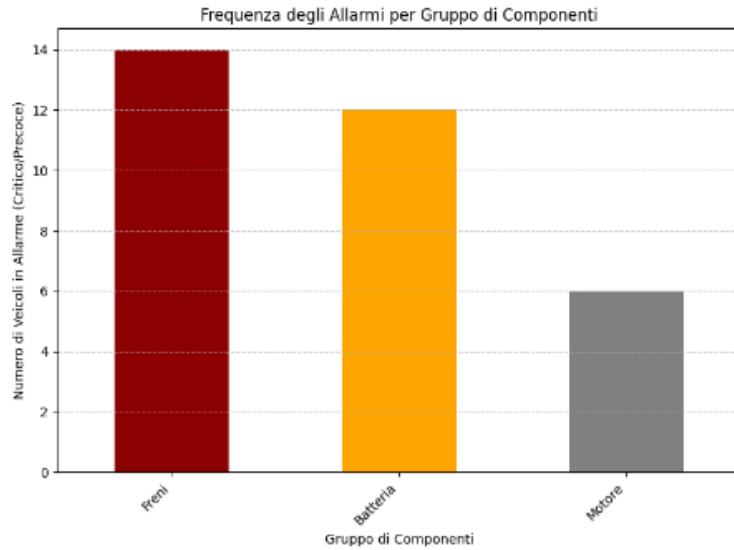


Figura 19 – Numero di veicoli in allarme individuati divisi per sottosistema dei componenti.

#### 6.4 Il calcolo della RUL con LSTM

Un’alternativa per il calcolo della RUL è l’algoritmo **Long Short Term Memory (LSTM)**, perché permette di creare delle sequenze temporali e addestrare una rete in grado di prevedere la vita utile rimanente. Questa tecnica di machine learning risulta più adeguata dal momento che l’usura e il degrado di un componente sono processi che dipendono dallo storico del veicolo. Inoltre, l’LSTM è progettato anche per gestire le dipendenze a lungo termine nei dati che sono elaborati dal modello, riuscendo a catturarne le tendenze e correlarli con i dati storici. Il dataset utilizzato per il modello precedente, tuttavia, è risultato incompatibile con LSTM a causa dei pochi dati disponibili nonostante l’applicazione di tecniche di data augmentation. Per poter applicare questo algoritmo, è stato utilizzato un altro dataset pubblico [102] composto da 47514 osservazioni di dati derivanti dal monitoraggio di 14 autoveicoli e con 30 variabili misurate; esse risultano simili al primo dataset con una maggior concentrazione sul monitoraggio dinamico della guida e sulle condizioni operative del motore, con indicazioni sul comportamento in tempo reale del propulsore e la segnalazione di codici di errore diagnostici. Quindi, a differenza del primo dataset che forniva, con molte meno osservazioni, una base dati completa per lo sviluppo del modello predittivo, questo secondo dataset è più focalizzato su pattern di comportamento del motore e sulla diagnostica OBD-II in tempo reale con un numero di osservazioni che permette l’applicazione di algoritmi LSTM per un calcolo più accurato della RUL.

Il modello si basa su un codice che riprende alcuni algoritmi utilizzati nel precedente modello: l’**Autoencoder** addestrato per calcolare la Reconstruction Loss e rilevare le anomalie, il classificatore **XGBoost** per predire le anomalie utilizzando i valori dei sensori e riconoscere i falsi positivi o negativi. A questi è stato aggiunto il **LSTM**, che ha permesso la creazione di 20 sequenze temporali (il modello non osserva un singolo punto dati, ma una finestra di 20 cicli consecutivi per fare la sua predizione) e l’addestramento di una rete che potesse predire la vita complessiva del veicolo in chilometri. Con lo scopo di quantificare l’anomalia del veicolo, è stato utilizzato anche l’**Isolation Forest**, un algoritmo di machine learning non supervisionato per misurare quanto il veicolo abbia dei parametri lontani da quelli attesi. Esso costruisce una foresta di alberi, andando a separare i dati con linee (note come iperpiani) finché ogni punto non è isolato. L’IF osserva quante separazioni sono

necessarie per isolare un punto specifico partendo dalla cima dell'albero: un punto anomalo richiede poche separazioni mentre un punto normale ne richiederà molte. L'IF\_Anomaly\_Score è calcolato sulla base della lunghezza media del percorso necessaria per isolare quel punto in tutti gli alberi.

L'obiettivo di questo modello non consiste nella sola stima della RUL del veicolo, ma anche nell'individuare il componente (o gruppo di componenti) responsabile della degradazione stimando la sua vita residua utile. Con questo scopo il modello utilizza due metriche: **il fattore di rischio e la RUL per componente**. Il primo consiste nella percentuale di errore di ricostruzione di ogni singolo sensore sulla Loss totale e consente di identificare l'elemento che causa l'anomalia. La RUL per componente è sostanzialmente la conversione del fattore di rischio in una vita residua espressa in chilometri.

I risultati del modello sono espressi tramite gli indici **OMI e VHI (Vehicle Health index)**. Quest'ultimo rappresenta la salute a lungo termine del veicolo basata sulla RUL predetta e si ottiene dal rapporto tra la RUL predetta e la massima RUL prevista dal modello. Infine, sulla base della percentuale di OMI e della RUL, viene definita una tipologia di priorità, le cui condizioni sono espresse nella Tabella 12.

*Tabella 12 – Criteri per l'assegnazione del livello di priorità all'interno del modello.*

Livello di Priorità	OMI (%)	RUL componente (Km)	Intervento richiesto
ALTA	OMI ≤ 2%	RUL ≤ 50 km	Intervento immediato e urgente. Il veicolo ha esaurito il margine di sicurezza.
MEDIA	2% < OMI ≤ 10%	50 Km < RUL ≤ 150 km	Pianificazione a breve termine. Il veicolo è entrato nella soglia di pericolo.
BASSA	OMI > 10%	RUL > 150 km	Monitoraggio continuo per effettuare interventi di manutenzione preventiva e prevenire il guasto.

I risultati degli output sono espressi tramite queste due tabelle: la prima (Figura 20) analizza lo stato di rischio per ogni veicolo, ordinato secondo la metrica OMI, che ha il compito di individuare il rischio operativo immediato. Tuttavia, il modello riesce a considerare anche la salute nel lungo periodo grazie al VHI e alla RUL predetta, risultando attento sia al guasto improvviso sia al degrado progressivo.

VEHICLE_ID	OMI (%)	VHI (%)	T_RC (Km)	RUL Predetta (Km)	Priorità Intervento	Codice DTC (RUL RCA)	Componente Rischio (RCA)
car10	0.00	40.52	0.00	3326.18	Alta	P0500	Speed
car14	2.25	49.12	107.93	4031.86	Media	P0500	Speed
car2	3.27	6.56	156.94	538.23	Media	P0190	Fuel Pressure
car11	5.14	30.79	246.83	2527.41	Media	P0110	Air Intake Temp
car4	6.84	10.03	328.38	823.09	Media	P0110	Air Intake Temp
car12	7.66	37.67	367.56	3092.33	Media	P9999	Generico
car1	8.63	10.11	414.06	829.54	Media	P0100	Maf
car3	9.65	9.65	462.98	791.76	Media	P0300	Engine Load
car9	10.34	40.98	496.14	3364.08	Bassa	P0100	Maf
car5	15.15	24.63	720.00	2021.72	Bassa	P0301	Engine Rpm
car7	22.11	40.43	720.00	3319.08	Bassa	P0110	Air Intake Temp
car13	29.47	47.16	720.00	3871.03	Bassa	P0115	Engine Coolant Temp
car6	47.19	63.49	720.00	5211.36	Bassa	P0120	Throttle Pos
car8	52.55	66.67	720.00	5472.37	Bassa	P0120	Throttle Pos

Figura 20 – Prima parte di output del codice.

La seconda tabella (Figura 21) invece approfondisce l’analisi, disaggregando il rischio per componente, specificando per ogni sensore il codice DTC associato, la RUL e il fattore di rischio.

vehicle_id	Componente	Sensore	Codice DTC Associato	RUL Componente (Km)	Fattore di Rischio (%)
car12	Air Intake Temp	air_intake_temp	P0110	189.61	187.99
car1	Speed	speed	P0500	212.83	236.91
car6	Throttle Pos	throttle_pos	P0120	220.76	262.37
car3	Speed	speed	P0500	224.98	280.14
car10	Speed	speed	P0500	226.68	288.65
car4	Air Intake Temp	air_intake_temp	P0110	228.04	296.22
car5	Engine Rpm	engine_rpm	P0301	228.05	575.23
car7	Air Intake Temp	air_intake_temp	P0110	228.05	480.90
car14	Engine Rpm	engine_rpm	P0301	228.05	476.24
car2	Fuel Pressure	fuel_pressure	P0190	228.05	376.17
car9	Maf	maf	P0100	228.05	370.81
car13	Engine Coolant Temp	engine_coolant_temp	P0115	228.05	347.42
car11	Air Intake Temp	air_intake_temp	P0110	228.05	316.66
car8	Throttle Pos	throttle_pos	P0120	228.05	302.59

Figura 21 - Seconda parte di output del codice.

Queste tabelle risultano fondamentali nella lettura del rischio che può essere distinto in localizzato e operativo: un esempio esemplificativo è la car5. Essa ha una priorità di intervento bassa, pur avendo il più alto fattore di rischio (575.23 % nella tabella in Fig. 20). Questo significa che l’anomalia, nonostante si discosti molto dai valori normali, risulta contenuta e non ha ancora compromesso la funzionalità complessiva del veicolo, permettendo una pianificazione preventiva non urgente, come la singola anomalia potrebbe aver fatto intendere. Questo risultato convalida il fatto che la priorità non debba essere guidata esclusivamente dalla sola gravità dell’anomalia statistica (misurata dall’AE), ma dalla sua rilevanza operativa nel sistema complessivo dell’autovettura (misurata da OMI e IF).

## 6.5 Conclusioni sui modelli elaborati

I due modelli presentati in questo lavoro di tesi hanno fatto comprendere come l'analisi dei dati in tempo reale dei veicoli risulti complessa a causa delle molteplici relazioni tra i componenti e i fattori esterni che possono influenzarne il funzionamento. Il primo modello è stato progettato con l'obiettivo di rilevare le anomalie e di associarle ai corrispondenti codici DTC, in modo tale da poter prevenire i guasti. L'aspetto di maggiore rilevanza non risiede nel singolo valore anomalo individuato, ma nel modo in cui tutte le anomalie presenti contribuiscono a risalire alla causa primaria del guasto. È stato messo in evidenza come le anomalie debbano essere analizzate nel loro contesto per poter capirne a pieno la causa scatenante. Il passo successivo aveva lo scopo di calcolare, a partire dall'analisi dei guasti precedente, la vita utile rimanente dei componenti del veicolo. L'obiettivo era quello di completare **il paradigma della manutenzione predittiva**, che non si ferma alla sola rilevazione del guasto ma ne vuole prevedere anche il momento per intervenire in modo tempestivo. Il primo approccio alla RUL è stato basato sul calcolo di una probabilità di guasto e sul superamento di una soglia elaborata dal modello. Tuttavia, l'usura e il degrado di un componente sono processi che dipendono dalla storia pregressa del veicolo e per gestire le dipendenze a lungo termine dei dati è necessario utilizzare un algoritmo di machine learning che basa le proprie previsioni sulla costruzione di sequenze temporali, come il Long Short-Term Memory. Dal momento che il dataset sintetico utilizzato non possedeva un numero di anomalie tali da permettere l'applicazione di questo algoritmo, è stato utilizzato un secondo set di dati più robusto per poter fornire in questo lavoro di tesi un primo approccio consistente e completo per il calcolo della RUL. In questa ultima elaborazione il modello è stato in grado di analizzare le anomalie, stabilendo un criterio di priorità sia sul breve sia sul lungo termine e andando a fornire un'analisi delle anomalie completa, differenziando quelle più critiche da quelle che il veicolo era in grado di gestire.

## CAPITOLO 7 - IMPLICAZIONI PDR

I modelli elaborati nel capitolo precedente rappresentano solo un primo passo verso un vero modello predittivo per la misura di affidabilità dei veicoli, anche per la mancanza di dati storici e per lo sviluppo solo su due singoli dataset. Il PDR completo potrebbe portare sicuramente molti vantaggi nell'ambito automobilistico, come maggior trasparenza sul mercato, dal momento che fornirebbe un sistema in grado di quantificare in modo oggettivo lo stato di un veicolo basandosi sulla reale condizione dei componenti. Inoltre, il progetto presenterebbe potenziali benefici anche sotto il profilo ambientale: un PDR in grado di stimare quante emissioni di CO<sub>2</sub> sono realmente emesse da un'autovettura porterebbe a una maggiore trasparenza nell'ambito delle regolamentazioni e delle politiche di restrizione legate alla circolazione delle autovetture. Queste misure di limitazione sono delle applicazioni di determinati principi dello sviluppo sostenibile, un ambito che negli ultimi anni ha acquisito maggior rilevanza a livello internazionale a causa dell'emergere di problematiche ambientali sempre più urgenti.

### 7.1 Il diritto dello sviluppo sostenibile: nascita e principi

Nel 1987, la Commissione Ambientale su Ambiente e Sviluppo (WCED), su mandato dell'ONU, ha pubblicato il Rapporto Brundtland, che ha coniato il concetto di **sviluppo sostenibile**, definito come:

*"Sviluppo che soddisfa i bisogni della generazione presente senza compromettere la capacità delle generazioni future di soddisfare i propri [103]. "*

Lo sviluppo sostenibile è una nozione che ha avuto molto successo in quanto capace di catturare la relazione tra tutela dell'ambiente, sviluppo economico e sviluppo sociale (definite le tre gambe dello sviluppo sostenibile). Nel contesto del diritto dello sviluppo sostenibile vi sono dei principi che regolano la tutela ambientale.

- Principio di precauzione: si applica nel momento in cui è presente un rischio di danno grave o irreversibile e, grazie a questo principio, non serve la certezza scientifica assoluta per adottare misure precauzionali.
- Principio di prevenzione: l'adozione di misure preventive serve per anticipare ed evitare danni ambientali prima che essi si verifichino. La differenza con il

precedente principio risiede nel fatto che in questo caso i possibili danni sono scientificamente provati.

- Principio della correzione, in via prioritaria, dei danni alla fonte: esso trova applicazione nel momento in cui il danno si è verificato, ossia quando hanno fallito gli altri due principi (prevenzione e precauzione) e fondamentalmente si cerca di evitare che i danni si amplifichino intervenendo direttamente alla fonte scatenante.
- Il principio “chi inquina paga”: Il costo delle attività dannose deve essere assunto da chi le provoca, per disincentivare il danno ambientale.
- Principio di integrazione: le esigenze ambientali devono essere prese in considerazione non come un elemento separato o marginale, ma insite in ogni politica, azione e decisione pubblica.
- Principio dello sviluppo sostenibile: riprende il concetto dei rapporti intergenerazionali pubblicato nel Rapporto Brundtland [104].

## **7.2 L'applicazione del principio di correzione, in via prioritaria, dei danni alla fonte**

Questi principi hanno influenzato conseguentemente anche il settore automobilistico negli anni. Il **principio della correzione, in via prioritaria, dei danni alla fonte** si applica nel momento in cui il danno è già avvenuto e si tenta di correggerlo alla fonte: lo scopo è arrestare l'effetto di amplificazione ed espansione, intervenendo alla radice del danno stesso. L'esempio applicativo migliore è proprio il limite alla circolazione delle vetture. Misure come le zone a basse emissioni (Low Emission Zones) o le limitazioni della circolazione per veicoli particolarmente inquinanti in città, tentano di ridurre il danno “alla fonte”, impedendo che veicoli con emissioni elevate entrino nel contesto urbano [105].

In Italia questo principio ambientale è stato incorporato nell' art. 3-ter del D.lgs. 152/2006: *“La tutela dell'ambiente e degli ecosistemi naturali e del patrimonio culturale deve essere garantita da tutti gli enti pubblici e privati e dalle persone fisiche e giuridiche pubbliche o private, mediante una adeguata azione che sia informata ai principi della precauzione, dell'azione preventiva, della correzione, in via prioritaria alla fonte, dei danni causati all'ambiente, nonché al principio ‘chi inquina paga’ [106].”*

Un esempio applicativo è il Decreto-Legge 121/2023 (“Misure urgenti in materia di pianificazione della qualità dell’aria e limitazioni della circolazione stradale”) che prevede che le regioni possano limitare la circolazione dei veicoli diesel Euro 5 nelle aree urbane quando superano i limiti di PM<sub>10</sub> o NO<sub>2</sub>. Per i comuni, l’articolo 7 del codice della strada prevede di *“limitare la circolazione di tutte o di alcune categorie di veicoli nei casi in cui risulti necessario, congiuntamente, nel rispetto dei criteri di proporzionalità e adeguatezza, ridurre le emissioni derivanti dal traffico veicolare in relazione ai livelli delle sostanze inquinanti nell’aria [107, 108].”*

### **7.3 Come il PDR potrebbe influire nell’ambito dello sviluppo sostenibile**

Una delle tre gambe dello sviluppo sostenibile riguarda proprio la giustizia sociale, la quale garantisce che i benefici dello sviluppo siano distribuiti equamente tra tutti i membri della società. Alcune misure di limitazione sulla circolazione degli autoveicoli, per quanto necessarie, possono risultare non sempre compatibili con la giustizia sociale. Oggi ci sono circa 40 milioni di auto e furgoni a diesel fortemente inquinanti sulle strade dell’Unione Europea, ma le autorità nazionali e locali, piuttosto che spingere i produttori ad apportare le modifiche necessarie, ricorrono sempre più alla riduzione degli ingressi dei veicoli in città, per limitare il numero delle auto circolanti sulle proprie strade ed impedire l’accesso ai mezzi più inquinanti.

Per garantire la piena applicazione del concetto di giustizia sociale in questo ambito, i criteri di inclusione e di esclusione si devono basare sui dati di rilevazione delle emissioni misurate in situazioni reali su strada (RDE) per ogni autoveicolo [109].

Le misure come le targhe alterne non si basano sul reale stato dei veicoli: limitare la circolazione dei veicoli in base all’ultima cifra della targa (pari o dispari) indipendentemente dalle reali emissioni di CO<sub>2</sub> non costituisce una misura pienamente corretta da un punto di vista sociale, poiché veicoli più recenti e meno inquinanti possono essere soggetti agli stessi divieti di quelli più vecchi e inquinanti. Un PDR che stabilisca un ranking basandosi sulle emissioni di CO<sub>2</sub>, tenendo quindi conto anche dello stile di guida dei conducenti, delle condizioni dei componenti sulla base delle manutenzioni effettuate, potrebbe essere utile in quanto permetterebbe ai veicoli meno impattanti di circolare, andando a limitare la

circolazione di quelli realmente più inquinanti e che impattano maggiormente sulle emissioni.

#### **7.4 Eco-Diagnostic**

L'aspetto ambientale va considerato in fase di manutenzione ma soprattutto in fase di progettazione. Nell'articolo "Economic and Ecological Aspects of Vehicle Diagnostics (ECO-Diagnostics)" i ricercatori della Széchenyi István University effettuano alcune considerazioni critiche riguardanti gli attuali sistemi di diagnostica: questi ultimi, secondo gli autori, non considerano l'impatto ecologico di una riparazione, focalizzandosi esclusivamente sul costo diretto del ricambio e della manodopera senza valutare l'impatto ambientale di una riparazione. Tuttavia, la sostituzione di un componente complesso può risultare più rapida per l'officina rispetto alla riparazione, ma potrebbe generare uno spreco di risorse più ingombrante. Per rispondere a queste esigenze è stato introdotto il concetto di **ECO-Diagnostic**: un approccio innovativo che integra i fattori ecologici con quelli economici nei test diagnostici tradizionali. Questo processo è guidato dai dati in tempo reale dei veicoli connessi (consumo, emissioni, usura) e richiede i database completi sull'impatto ambientale dei singoli componenti e algoritmi di intelligenza artificiale in grado di pesare costi e benefici sia economici sia ambientali, suggerendo la scelta più vantaggiosa. In un contesto in costante evoluzione come quello automobilistico, l'Eco-Diagnostic può avere un ruolo sempre più centrale all'interno dei processi diagnostici del settore automotive [110].

## CAPITOLO 8 - CONCLUSIONI

Il presente lavoro di tesi è stato articolato inizialmente in una prima fase di ricerca e successivamente in una parte di programmazione in cui, partendo dalle basi teoriche, sono stati sviluppati alcuni modelli che potessero rappresentare un primo approccio operativo verso la realizzazione del nuovo PDR.

La prima fase di ricerca ha avuto lo scopo di comprendere principalmente come le case automobilistiche oggi effettuino la manutenzione: il risultato è stato apprendere che ormai esse si stanno spostando sempre più verso una manutenzione predittiva, che si basa sul reale stato dei componenti (Condition Based Maintenance). Le tecnologie comprese in questo nuovo paradigma manutentivo sono principalmente i sensori IoT per la raccolta dati, il Cloud per il loro immagazzinamento e gli algoritmi di machine learning per l'elaborazione con la finalità di rilevare e predire eventuali guasti. Una differenza tra le varie case automobilistiche riguarda le modalità tramite cui stanno affrontando questo cambiamento: alcune in proprio tramite intere divisioni software, altre in partnership con aziende specializzate nel campo dell'intelligenza artificiale e dei servizi Cloud. In ogni caso, tutto il settore sta andando nella direzione della raccolta e della valorizzazione dei dati in tempo reale, che costituiscono una risorsa fondamentale nel campo della manutenzione predittiva odierna.

Prima di procedere alla seconda fase è stato necessario capire quali siano in letteratura gli algoritmi più adatti per il modello di manutenzione predittiva. L'Autoencoder, combinato con algoritmi Random Forest, è stata la soluzione adottata per la sua efficacia nell'identificazione di anomalie, minimizzando l'errore di ricostruzione. Partendo da queste basi, è iniziata la seconda fase del lavoro di tesi: l'elaborazione del modello predittivo. Il dataset di partenza era composto da dati sintetici pubblici, che raccoglievano i principali parametri presi dai sistemi OBD. L'applicazione dei due precedenti algoritmi ha permesso da una parte di rilevare valori anormali del dataset e successivamente di analizzarne le reciproche correlazioni, fornendo un quadro manutentivo ampio, in grado di evidenziare non solo le anomalie dirette ma anche le loro cause indirette, associando i codici di guasto DTC.

Dopo la fase di identificazione delle anomalie, il passaggio successivo risiede nell'associazione dei potenziali guasti alla vita utile rimanente dei componenti. Questa

relazione rappresenta l'essenza della manutenzione predittiva, che vuole prevedere anche il momento del possibile guasto per intervenire in modo tempestivo. Quindi la diagnostica DTC ha lo scopo di individuare la causa del guasto, mentre la previsione della RUL è necessaria per comprendere quando esso avverrà. Per questo ultimo scopo l'algoritmo XGBoost, oltre a prevedere un guasto imminente (con classificazione binaria), produce anche una probabilità di guasto. Nel seguente modello la RUL è indicata come stima temporale, espressa in giorni, del tempo rimanente prima che il componente o il veicolo possa subire un guasto. Per i casi meno critici viene fornita una RUL approssimativa statica e, per quelli più imminenti (nell'arco di sette giorni), una RUL dinamica che riflette l'effettivo stato del componente.

Nell'ultima fase di elaborazione del modello, l'obiettivo è stato stimare la vita utile rimanente in modo più preciso: l'usura e il degrado di un componente, infatti, sono processi strettamente correlati al tempo di funzionamento; per questo motivo nel modello sono stati integrati algoritmi quali Isolation Forest, per quantificare le anomalie e andare oltre la semplice rilevazione e LSTM, per catturarne le dipendenze temporali presenti nei dati. Per poter permettere l'applicazione di tale algoritmo è stato usato un secondo dataset più robusto con molte più osservazioni, per fornire un approccio consistente e completo per il calcolo della RUL.

Come già precedentemente affermato, i modelli elaborati rappresentano un primo passo rispetto a un vero modello predittivo per la misura di affidabilità dei veicoli. Il PDR completo potrebbe essere un futuro strumento di garanzia di maggior trasparenza sul mercato, dal momento che fornirebbe un sistema in grado di quantificare in modo oggettivo un veicolo basandosi sul reale stato dei componenti. I passi successivi da effettuare riguardano l'applicazione su dati reali monitorati tramite OBD e l'integrazione del modello con i dati storici di manutenzione collegati a quelli in tempo reale elaborati dallo stesso. Questo fornirebbe un contesto che garantirebbe all'algoritmo un riferimento completo in cui inserire le proprie previsioni di RUL.

Dal punto di vista ambientale, un PDR completo in grado di stimare quante emissioni di CO<sub>2</sub> siano realmente emesse da un veicolo porterebbe a una maggiore trasparenza nell'ambito delle regolamentazioni e delle politiche di restrizione legate alla circolazione delle autovetture. Inoltre, potrebbe contribuire ad alimentare il concetto di giustizia sociale, una

delle tre gambe che sostengono lo sviluppo sostenibile, andando a fornire un metro di giudizio più meritevole rispetto ad alcune restrizioni basate su principi casuali e non equi per tutti i conducenti. Di conseguenza, il PDR può essere lo strumento che rappresenta il punto d'incontro tra l'affidabilità tecnica e la sostenibilità ambientale per una mobilità che rispecchi i principi dello sviluppo sostenibile.



## RIFERIMENTI

- [1] K. Bond and S. Butler-Sloss, "The EV Revolution in Five Charts and Not Too Many Numbers," RMI, Sep. 21, 2023. [Online]. Available: <https://rmi.org/the-ev-revolution-in-five-charts-and-not-too-many-numbers>
- [2] D. Ministeri, "The Global BEV Transition: same destination, different speeds across regions," JATO, Jul. 18, 2025. [Online]. Available: <https://www.jato.com/resources/news-and-insights/the-global-bev-transition-same-destination-different-speeds-across-regions>
- [3] OICA, "Global auto production in 2020 severely hit by COVID-19 crisis with a 16% drop in world auto production," OICA, Mar. 24, 2021. [Online]. Available: <https://www.oica.net/global-auto-production-in-2020-severely-hit-by-covid-19-crisis-with-a-16-drop-in-world-auto-production/>
- [4] MHP Management- und IT-Beratung GmbH, "Industry 4.0 Barometer 2024," MHP, Mar. 2024. [Online]. Available: [https://www.mhp.com/fileadmin/www.mhp.com/downloads/whitepaper/MHPStudy\\_2024\\_Industry\\_4\\_0\\_Barometer\\_EN.pdf](https://www.mhp.com/fileadmin/www.mhp.com/downloads/whitepaper/MHPStudy_2024_Industry_4_0_Barometer_EN.pdf)
- [5] IEA, "Global EV Outlook 2025: Executive Summary," IEA, May 14, 2025. [Online]. Available: <https://www.iea.org/reports/global-ev-outlook-2025/executive-summary>
- [6] KPMG, "Impact of Emerging Trends on the Auto Industry," KPMG, 2023. [Online]. Available: <https://kpmg.com/kpmg-us/content/dam/kpmg/pdf/2023/impact-auto-industry.pdf>
- [7] Statista, "Italy – projected used car industry size 2021-2027," [Online]. Available: <https://www.statista.com/statistics/1361768/italy-used-car-industry-size-forecast/>
- [8] G. A. Akerlof, "The Market for Lemons: Quality Uncertainty and the Market Mechanism," Quarterly Journal of Economics
- [9] Ekonomia.it, "Le domande improvvise: Akerlof ed il mercato dei limoni," Ekonomia.it, Jun. 18, 2024. [Online]. Available: <https://www.ekonomia.it/2024/06/18/le-domande-improvvide-akerlof-ed-il-mercato-dei-limoni/>
- [10] F. Galetto, Affidabilità Volume Primo: Teoria e Metodi di Calcolo, Torino, Italia: CLEUP, 1989.
- [11] C. Delprete e D. Paolino, pdf, corso di "Affidabilità, Sicurezza e Manutenzione per l'Azienda", Politecnico di Torino, DIMEAS, Torino, Italia, 2022
- [12] National Institute of Standards and Technology (NIST), "8.1.6. What are the basic lifetime distribution models used for non-repairable populations?" e-Handbook of Statistical Methods, 16 apr. 2012. [Online]. Available: <https://www.itl.nist.gov/div898/handbook/apr/section1/apr16.htm>
- [13] Wikipedia, Manutenzione, <https://it.wikipedia.org/wiki/Manutenzione>

- [14] M. Lazzaroni, Affidabilità dei sistemi – Appunti di Teoria dei Sistemi, Università degli Studi di Milano. [Online]. Available: <https://www.docsity.com/it/docs/affidabilita-dei-sistemi/10836529/>
- [15] A. Kotb, “The relation between maintenance and reliability,” Reliability Connect, 9 Feb. 2022. [Online]. Available: <https://www.reliabilityconnect.com/the-relation-between-maintenance-and-reliability>
- [16] De Franceschini L., “Reliability and maintenance of production plants: a case of study in the automotive sector”, Tesi di Laurea Triennale in Ingegneria Gestionale, 2024
- [17] CARL Berger-Levrault, “Manutenzione: evoluzione e tipologie,” Newsletter CMMS, 1 giu. 2023. [Online]. Available: <https://www.carl-software.it/newsletter-cmms-manutenzione-evoluzione-e-tipologie/>
- [18] P. Mella, Teoria della Manutenzione, A.A. 2016–2017, Università degli Studi di Pavia, Dipartimento di Scienze Economiche e Aziendali, Corso di Economia Aziendale – Teoria del Controllo. [Online]. Available: [https://www.pieromella.it/lucidi%20web/lucidi2013teoriadelcontrollo\\_file/manutenzione.pdf](https://www.pieromella.it/lucidi%20web/lucidi2013teoriadelcontrollo_file/manutenzione.pdf)
- [19] Mainsim, “Tipi di manutenzione,” Mainsim CMMS Academy, 5 apr. 2018. [Online]. Available: <https://www.mainsim.com/academy/tipi-di-manutenzione/>
- [20] Mainsim, “Manutenzione preventiva,” Mainsim CMMS Academy, 5 lug. 2018. [Online]. Available: <https://www.mainsim.com/academy/manutenzione-preventiva/>
- [21] Infraspeak Team, “The complete guide to Time-Based Maintenance (TBM),” Infraspeak Blog, 5 feb. 2024. [Online]. Available: <https://blog.infraspeak.com/time-based-maintenance/>
- [22] T. Goncalves, “What Is Condition-Based Maintenance (CBM)?,” Fiix Software, 14 lug. 2022. [Online]. Available: <https://fiixsoftware.com/maintenance-strategies/condition-based-maintenance/>
- [23] Dipartimento DMAE, Università di Pavia, materiale didattico, Università di Pavia. [Online]. Available: [http://www-9.unipv.it/dmae/diagnostica/materiale\\_didattico/Diagnostica\\_1.pdf](http://www-9.unipv.it/dmae/diagnostica/materiale_didattico/Diagnostica_1.pdf)
- [24] A. P. Daga and L. Garibaldi, “Machine Vibration Monitoring for Diagnostics through Hypothesis Testing,” Information, vol. 10, no. 6, p. 204, 2019. [Online]. Available: <https://doi.org/10.3390/info10060204>
- [25] Eurolab, “Che cos’è la termografia e quali sono i suoi vantaggi,” Eurolab News, 15 mar. 2021. [Online]. Available: <https://www.eurolab.mi.it/news/14-che-cos-la-termografia-e-quali-sono-i-suoi-vantaggi>

- [26] A. Zararsiz, "X-ray fluorescence analysis of wear metals in used lubricating oils," Nuclear Instruments and Methods in Physics Research Section B: Beam Interactions with Materials and Atoms, vol. 109–110, pp. 457–461, 1996. [https://doi.org/10.1016/0168-583X\(95\)01156-0](https://doi.org/10.1016/0168-583X(95)01156-0)
- [27] S. S. Kumar, R. Singh, and A. Verma, "Machinery Fault Detection Through Ultrasound Technology," SPE Oil & Gas Technology, Dec. 2021. [Online]. Available: <https://doi.org/10.2118/204812-MS>
- [28] M. Chen, "What Is Machine Learning?," Oracle, Nov. 25, 2024. [Online]. Available: <https://www.oracle.com/artificial-intelligence/machine-learning/what-is-machine-learning/>
- [29] "What Is Machine Learning? Key Concepts and Real-World Uses," Syracuse University iSchool, 7 mesi fa. [Online]. Available: <https://ischool.syracuse.edu/what-is-machine-learning/>
- [30] A. Minini, "La regressione nel machine learning," Andreaminini.com, [Online]. Available: <https://www.andreaminini.com/ai/machine-learning/la-regressione-nel-machine-learning>
- [31] A. Minini, "Classificazione nel Machine Learning," Andreaminini.com, [Online]. Available: <https://www.andreaminini.com/ai/machine-learning/classificazione-machine-learning>
- [32] "Algoritmi di Machine Learning – guida introduttiva per comprendere i principi e le applicazioni," Diario di un Analista, [Online]. Available: <https://www.diariodiunanalista.it/posts/algoritmi-di-machine-learning-guida-introduttiva-per-comprendere-i-principi-e-le-applicazioni/>
- [33] J. Cervantes, "A comprehensive survey on support vector machine (SVM) and its applications in machine learning," Computers and Electronics in Agriculture, vol. 178, p. 105773, 2020. [Online]. Available: <https://doi.org/10.1016/j.compag.2020.105773>
- [34] Databricks, "Modelli di machine learning (Machine Learning Models)," Glossario Databricks, [Online]. Available: <https://www.databricks.com/it/glossary/machine-learning-models>
- [35] "What is the k-nearest neighbors (KNN) algorithm?" IBM, [Online]. Available: <https://www.ibm.com/think/topics/knn>
- [36] M. N. Hossain, M. M. Rahman, and D. Ramasamy, "Artificial Intelligence-Driven Vehicle Fault Diagnosis to Revolutionize Automotive Maintenance: A Review," Computer Modeling in Engineering & Sciences, 2024. <https://doi.org/10.32604/cmes.2024.056022>

- [37] Y. S. Wang, N. N. Liu, H. Guo, and X. L. Wang, "An engine-fault-diagnosis system based on sound intensity analysis and wavelet packet pre-processing neural network," *Engineering Applications of Artificial Intelligence*, 2020.
- <https://doi.org/10.1016/j.engappai.2020.103765>
- [38] C. M. Bishop, *Pattern Recognition and Machine Learning*, New York, NY, USA: Springer, 2006. <https://link.springer.com/book/9780387310732>
- [39] "What is a Neural Network?" AWS, [Online]. Available: <https://aws.amazon.com/it/what-is/neural-network/>
- [40] T. Khoualdia, A. Lakehal, Z. Chelli, K. Khoualdia, and K. Nessaib, "Optimized multi layer perceptron artificial neural network based fault diagnosis of induction motor using vibration signals," *Diagnostyka*, 2021. [Online]. Available: <https://doi.org/10.29354/diag/133091>
- [41] D. Li, Z. Zhang, P. Liu, Z. Wang, and L. Zhang, "Battery fault diagnosis for electric vehicles based on voltage abnormality by combining the long short-term memory neural network and the equivalent circuit model," 2021. [Online]. Available: <https://doi.org/10.1109/TPEL.2020.300>
- [42] S. Iftikhar Shoaib et al., "A deep learning approach to optimize remaining useful life prediction for Li-ion batteries," *Scientific Reports*, vol. 14, p. 77427, 2024. [Online]. Available: <https://doi.org/10.1038/s41598-024-77427-1>
- [43] "Manutenzione predittiva," Wikipedia, [Online]. Available: [https://it.wikipedia.org/wiki/Manutenzione\\_predittiva](https://it.wikipedia.org/wiki/Manutenzione_predittiva)
- [44] I. Katser, "All you want to know about determining remaining useful life (RUL) of industrial equipment," Medium, [Online]. Available: <https://medium.com/@katser/all-you-want-to-know-about-determining-remaining-useful-life-rul-of-industrial-equipment-6a88dc71a0ac>
- [45] S. Kumar, K. K. Raj, M. Cirrincione, G. Cirrincione, V. Franzitta, and R. R. Kumar, "A Comprehensive Review of Remaining Useful Life Estimation Approaches for Rotating Machinery," 2024. [Online]. Available: <https://doi.org/10.3390/en17225538>
- [46] M. Blann, "Understanding Predictive Maintenance," [PDF], anno. [Online]. Available: [https://assets.ctfassets.net/f0vishkpk0qq/1ap5bg93IPkSrCQ0xhM5xk/76909633c87683ae3e59cccd3304af41/understanding\\_predictive\\_maintenance.pdf](https://assets.ctfassets.net/f0vishkpk0qq/1ap5bg93IPkSrCQ0xhM5xk/76909633c87683ae3e59cccd3304af41/understanding_predictive_maintenance.pdf)
- [47] J. Furch e Z. Krobot, "Trends in Predictive and Proactive Maintenance of Motor Vehicles," *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis*, 2020. [Online]. Available: <https://doi.org/10.11118/actaun202068020311>

- [48] I. Hector and R. Panjanathan, “Predictive maintenance in Industry 4.0: a survey of planning models and machine learning techniques,” PeerJ Comput. Sci, 2024. [Online]. Available: <https://pmc.ncbi.nlm.nih.gov/articles/PMC11157603/>
- [49] “The Ultimate Guide to Automotive Telematics,” AcsiaTech, [Online]. Available: <https://www.acsiatech.com/the-ultimate-guide-to-automotive-telematics/>
- [50] O. Weinmann, “Software updates in the IoT: an introduction to SOTA,” Bosch Digital Blog, 2018. [Online]. Available: <https://blog.bosch-digital.com/software-updates-in-the-iot-an-introduction-to-sota/>
- [51] M. Bertoncello, C. Martens, T. Möller, and T. Schneiderbauer, “Unlocking the full life-cycle value from connected-car data,” McKinsey & Company, Feb. 11, 2021. [Online]. Available: <https://www.mckinsey.com/industries/automotive-and-assembly/our-insights/unlocking-the-full-life-cycle-value-from-connected-car-data>
- [52] Geotab, “La telematica OEM e i suoi vantaggi per la tua flotta,” Geotab Blog, 15 set. 2022. [Online]. Available: <https://www.geotab.com/it/blog/telematica-oem-vantaggi-per-la-flotta/>
- [53] MICHELIN Connected Fleet, “What OEM Telematics Means in Fleet Management,” MICHELIN Connected Fleet Blog. [Online]. Available: <https://connectedfleet.michelin.com/blog/what-oem-telematics-means-in-fleet-management>
- [54] “Association for Standardisation of Automation and Measuring Systems,” Wikipedia, [Online]. Available: [https://en.wikipedia.org/wiki/Association\\_for\\_Standardisation\\_of\\_Automation\\_and\\_Measuring\\_Systems](https://en.wikipedia.org/wiki/Association_for_Standardisation_of_Automation_and_Measuring_Systems)
- [55] “ASAM e.V.,” ASAM, [Online]. Available: <https://www.asam.net/>
- [56] “Verband der Automobilindustrie,” Wikipedia, [Online]. Available: [https://en.wikipedia.org/wiki/Verband\\_der\\_Automobilindustrie](https://en.wikipedia.org/wiki/Verband_der_Automobilindustrie)
- [57] “Verband der Automobilindustrie,” VDA, [Online]. Available: <https://www.vda.de/en>
- [58] “International Automotive Task Force,” Wikipedia, [Online]. Available: [https://en.wikipedia.org/wiki/International\\_Automotive\\_Task\\_Force](https://en.wikipedia.org/wiki/International_Automotive_Task_Force)
- [59] “IATF 16949:2016 Certification,” NQA, [Online]. Available: <https://www.nqa.com/en-us/certification/standards/iatf-16949>
- [60] “Automotive Industry Action Group,” Wikipedia, [Online]. Available: [https://en.wikipedia.org/wiki/Automotive\\_Industry\\_Action\\_Group](https://en.wikipedia.org/wiki/Automotive_Industry_Action_Group)
- [61] “Automotive Industry Action Group,” AIAG, [Online]. Available: <https://www.aiag.org/about-aiag>

- [62] “J1979-2\_202104 - E/E Diagnostic Test Modes: OBDOnUDS,” SAE, [Online]. Available: [https://www.sae.org/standards/j1979-2\\_202104-e-e-diagnostic-test-modes-obdonuds](https://www.sae.org/standards/j1979-2_202104-e-e-diagnostic-test-modes-obdonuds)
- [63] “Society of Automotive Engineers,” Wikipedia, [Online]. Available: [https://it.wikipedia.org/wiki/Society\\_of\\_Automotive\\_Engineers](https://it.wikipedia.org/wiki/Society_of_Automotive_Engineers)
- [64] “Automotive Electronics Council,” Wikipedia, [Online]. Available: [https://en.wikipedia.org/wiki/Automotive\\_Electronics\\_Council](https://en.wikipedia.org/wiki/Automotive_Electronics_Council)
- [65] “Automotive Electronics Council (AEC),” AEC, [Online]. Available: <https://www.aecouncil.com/>
- [66] “Vehicle Data and Predictive Maintenance,” Cariad Technologies, [Online]. Available: <https://cariad.technology/de/en/news/stories/vehicle-data-predictive-maintenance.html>
- [67] “Targa Telematics Partnership Signed with Volkswagen Group Info Services AG for Fleet Data” Targa Telematics, [Online]. Available: <https://targatelematics.com/media/press-release/targa-telematics-partnership-signed-with-volkswagen-group-info-services-ag-for-fleet-data-integration-from-volkswagen-passenger-cars-volkswagen-commercial-vehicles-audi-skoda-seat-cupra-vehicles/>
- [68] “Volkswagen and Geotab Announce OEM Telematics Partnership,” Geotab Press Release, [Online]. Available: <https://www.geotab.com/press-release/oem-volkswagen-partnership/>
- [69] “Condition Based Service – What is it?,” Knauz BMW, [Online]. Available: <https://www.knauzbmw.com/condition-based-service-information.htm>
- [70] “BMW Teleservices,” BMW, [Online]. Available: <https://www.bmw.it/it/topics/mondo-bmw/bmw-connecteddrive/bmw-teleservices.html>
- [71] “5 ways Mercedes-Benz is using AI [Case Study],” DigitalDefynd, [Online]. Available: <https://digitaldefynd.com/IQ/mercedes-benz-using-ai-case-study/>
- [72] “MO360 data platform,” Mercedes-Benz Group – Innovation/Industry 4.0, [Online]. Available: <https://group.mercedes-benz.com/innovation/digitalisation/industry-4-0/mo360-data-platform.html>
- [73] M. Bertoncello, C. Martens, T. Möller & T. Schneiderbauer, “What is the Mercedes-MB.OS operating system?” J.D. Power, 10 Oct. 2023. [Online]. Available: <https://www.jdpower.com/cars/shopping-guides/what-is-the-mercedes-mb-os-operating-system>
- [74] “How to use Xentry Diagnostics,” AutoExplain, [Online]. Available: <https://autoexplain.com/how-to-use-xentry-diagnostics/>
- [75] “Flexible Service System,” BenzShops, [Online]. Available: <https://www.benzshops.com/mercedes-flexible-service-system>

- [76] "Ford presents FORDLiive – un innovativo sistema connesso e integrato per la manutenzione predittiva," Ford Media Center, 22 Mar. 2021. [Online]. Available: <https://media.ford.com/content/fordmedia/feu/it/it/news/2021/03/22/ford-presenta-fordliive--un-innovativo-sistema-connesso-e-integr.html>
- [77] "Patent US 12189383 – Analysis of vehicle data to predict component failure," Justia Patents. [Online]. Available: <https://patents.justia.com/patent/12189383>
- [78] "Ford predicting failures using connected vehicle data – AI example," Kortical Case Studies. [Online]. Available: <https://kortical.com/case-studies/ford-predicting-failures-ai-example>
- [79] "Manutenzione veicolo: che cos'è il monitoraggio intelligente della durata dell'olio," Ford Italia Supporto, [Online]. Available: <https://www.ford.it/supporto/come-fare/risorse-aziendali/manutenzione-veicolo/che-cose-il-monitoraggio-intelligente-della-durata-dellolio>
- [80] "General Motors announces industry-first prognostic tech to predict component failure," GM Authority, 4 Gen. 2015. [Online]. Available: <https://gmauthority.com/blog/2015/01/general-motors-announces-industry-first-prognostic-tech-to-predict-component-failure/>
- [81] C. Golden, "GM OnStar Adds Predictive Maintenance, Driver Feedback Program," MotorTrend, 5 Gen. 2015. [Online]. Available: <https://www motortrend com/news/gm-onstar-adds-predictive-maintenance-driver-feedback-program>
- [82] "General Motors e l'intelligenza artificiale: come cambia l'auto fra fabbrica, officina e marketing," Automoto.it, [Online]. Available: [< https://www.automoto.it/news/general-motors-e-l-intelligenza-artificiale-come-cambia-l-auto-tra-fabbrica-officina-e-marketing.html](https://www.automoto.it/news/general-motors-e-l-intelligenza-artificiale-come-cambia-l-auto-tra-fabbrica-officina-e-marketing.html)
- [83] "Diagnostic Support Resources | GM Parts," GM Parts Technical Resources, [Online]. Available: <https://www.gmparts.com/technical-resources/diagnostic-support-resources>
- [84] "Toyota and Generative AI: It's Here, and This Is How We're Using It," Toyota Media Center, [Online]. Available: <https://pressroom.toyota.com/toyota-and-generative-ai-its-here-and-this-is-how-were-using-it/>
- [85] "Inside Toyota's 2025 Leaner Manufacturing System," Automotive Manufacturing Solutions, [Online]. Available: <https://www.automotivemanufacturingsolutions.com/editors-pick/inside-toytas-2025-leaner-manufacturing-system/645325>
- [86] "Mobilisights drives the telematic future with integrated fleet management data package in the MY24 Pro One range," Stellantis Media, March 20, 2024. [Online]. Available: <https://www.media.stellantis.com/em-en/mobilisights/press/mobilisights-drives-the->

telematic-future-with-integrated-fleet-management-data-package-in-the-my24-pro-one-range

[87] “FCA selects Harman Samsung and Google technologies for new global connected vehicle ecosystem,” Stellantis Media, [Online]. Available:

<https://www.media.stellantis.com/uk-en/fca-archive/press/fca-selects-harman-samsung-and-google-technologies-for-new-global-connected-vehicle-ecosystem>

[88] “Stellantis migliora l’esperienza di mobilità personalizzata con l’acquisizione delle tecnologie di intelligenza artificiale e della proprietà intellettuale di CloudMade,” Stellantis, January 2024. [Online]. Available:

<https://www.stellantis.com/it/news/comunicati-stampa/2024/gennaio/stellantis-migliora-l-esperienza-di-mobilita-personalizzata-con-l-acquisizione-delle-tecnologie-di-intelligenza-artificiale-e-della-proprietà-intellettuale-di-Cloudmade>

[89] M. Cantamessa and F. Montagna, Management of Innovation and Product Development: Integrating Business and Technological Perspectives, 2nd ed., London, UK: Springer, 2023. doi: <https://link.springer.com/book/10.1007/978-1-4471-7531-5>

[90] U.S. E.P.A., Clean Air Act, 1990.

[91] “What is OBD? Understanding On-Board Diagnostics,” Noregon, [Online]. Available: <https://www.noregon.com/what-is-obd/>

[92] “OBD-II Overview,” Geotab Blog, [Online]. Available: <https://www.geotab.com/blog/obd-ii/>

[93] Nasello E., “Studio di modelli di sostenibilità per l’utilizzo e il riutilizzo dei veicoli usati”, tesi di laurea magistrale, Politecnico di Torino, Torino, Italia, 2025.

[94] “SAE J1979 – OBD II,” Automotive Vehicle Testing, [Online]. Available: <https://automotivevehicletesting.com/vehicle-diagnostics/sae-j1979-obd-ii/>

[95] “Diagnostic Standards OBDDonUDS / SAE J1979-2,” Vector Solutions, [Online]. Available: <https://www.vector.com/us/en/products/solutions/diagnostic-standards/obdonuds/>

[96] “Regulation (EC) No 715/2007 of the European Parliament and of the Council,” EUR-Lex, [Online]. Available: <https://eur-lex.europa.eu/eli/reg/2007/715/oj/eng>

[97] “CANedge – Getting Started – Introduction,” CSS Electronics, [Online]. Available: <https://canlogger.csselectronics.com/canedge-getting-started/ce3/introduction/>

[98] T. A. Tejalaveti, “Vehicle Maintenance Telemetry Data,” Kaggle Dataset, 2024. [Online]. Available: <https://www.kaggle.com/datasets/tejalaveti2306/vehicle-maintenance-telemetry-data>

[99] GITHUB – Cartella contenente i tre codici sviluppati per il modello predittivo [https://github.com/LucaFavero001/Codici\\_Modello\\_Manutenzione\\_Predittiva](https://github.com/LucaFavero001/Codici_Modello_Manutenzione_Predittiva)

- [100] “Fault Detection Through Ultrasound Technology,” PMC, [Online]. Available: <https://PMC11519505/>
- [101] “Fault Detection Through Ultrasound Technology,” Applied Sciences, vol. 14, no. 13, p. 5847, 2024. [Online]. Available: <https://www.mdpi.com/2076-3417/14/13/5847>
- [102] C. Axelsson, “OBD-II datasets,” Kaggle Dataset, 2017. [Online]. Available: <https://www.kaggle.com/datasets/cephasax/obdii-ds3>
- [103] “Il principio dello sviluppo sostenibile nel diritto internazionale,” Mondo Internazionale, [Online]. Available: <https://mondointernazionale.org/post/il-principio-dello-sviluppo-sostenibile-nel-diritto-internazionale>
- [104] “Introduzione al diritto ambientale dell’UE – Modulo 2.8,” European Law Academy (ERA), [Online]. Available:  
[https://www.era-comm.eu/Introduction\\_EU\\_Environmental\\_Law/IT/stand\\_alone/module\\_2/module\\_2\\_8.html](https://www.era-comm.eu/Introduction_EU_Environmental_Law/IT/stand_alone/module_2/module_2_8.html)
- [105] “Qualità dell’aria e mobilità sostenibile – Low Emission Zones (LEZ),” Conferenza Stato-Città, [Online]. Available: [https://www.conferenzastatocitta.it/home/la-conferenza-e-europa/tematiche-europee-di-interesse-degli-enti-locali/enti-territoriali-e-sviluppo-sostenibile/1\\_qualita-dell-aria-e-mobilita-sostenibile-low-emission-zones-lez/](https://www.conferenzastatocitta.it/home/la-conferenza-e-europa/tematiche-europee-di-interesse-degli-enti-locali/enti-territoriali-e-sviluppo-sostenibile/1_qualita-dell-aria-e-mobilita-sostenibile-low-emission-zones-lez/)
- [106] “Decreto Legislativo 3 aprile 2006, n. 152 – Norme in materia ambientale,” Normattiva, [Online]. Available: <https://www.normattiva.it/uri-res/N2Ls?urn:nir:stato:decreto.legislativo:2006-04-03;152>
- [107] “Tutela dell’ambiente – Inquinamento atmosferico,” Edizioni Europee, [Online]. Available: [https://www.edizionieuropee.it/law/html/221/zn56\\_02\\_257.html](https://www.edizionieuropee.it/law/html/221/zn56_02_257.html)
- [108] “Codice della Strada – Articolo 7,” Brocardi.it, [Online]. Available: <https://www.brocardi.it/codice-della-strada/titolo-i/art7.html>
- [109] “Eliminare i diesel dalle città,” Cittadini per l’Aria ONLUS / Transport & Environment, Apr. 2018. [Online]. Available: <https://www.cittadiniperlaria.org/wp-content/uploads/2018/04/ITA-Eliminare-i-diesel-dalle-citt%C3%A0-Transport-Environment.pdf>
- [110] I. Lakatos, “Economic and Ecological Aspects of Vehicle Diagnostics,” Sustainability. [Online]. Available: <https://doi.org/10.3390/su17041662>

