### POLITECNICO DI TORINO

Corso di Laurea Magistrale in Ingegneria Meccanica

Tesi di Laurea Magistrale

# Modello di calcolo predittivo per le valvole di controllo

Un approccio basato su fisica e logiche di autoapprendimento per l'ottimizzazione della produzione dei servocomandi primari



### Relatori

prof. Massimo Sorli

dott. Antonio Carlo Bertolino

dott. Andrea De Martin

Candidato

Marco Del Giudice

Tutor Aziendale Microtecnica s.r.l

Ing. Dario Savino

Anno Accademico 2024/2025

All models are wrong, but some are useful George E. P. Box

# Sommario

Le valvole idrauliche per applicazioni aeronautiche richiedono tolleranze produttive estremamente strette, poiché minime deviazioni nei parametri di produzione possono compromettere irrimediabilmente le prestazioni dei servosistemi. Questa tesi propone un framework innovativo per l'analisi della produzione delle *Main Control Valves* (MCV) del *Main Control Actuator* (MCA) dell'elicottero AW169, combinando modellazione fisico-matematica e apprendimento automatico.

L'approccio adottato integra un modello basato su equazioni fisiche, calibrato sui dati sperimentali, con algoritmi di *Machine Learning* per l'analisi dei test condotti in fase di produzione. L'obiettivo è identificare trend nascosti e derive statistiche indicative di criticità produttive. L'analisi automatizzata consente di rilevare tempestivamente anomalie nei processi produttivi, prevenendo difetti e garantendo la conformità ai requisiti tecnici.

Il lavoro si articola in quattro fasi principali: lo studio del sistema di controllo del rotore e del ruolo della MCV, la formulazione matematica del modello idraulico, la sua implementazione in MATLAB/Simulink e l'applicazione di algoritmi di apprendimento automatico per supportare le analisi.

I risultati suggeriscono che l'integrazione tra modellazione fisica e algoritmi di autoapprendimento possa costituire un valido strumento per migliorare la produzione, favorendo un maggiore controllo sulla qualità dei componenti e una gestione più efficiente delle risorse. Inoltre, l'approccio sviluppato potrebbe essere esteso all'analisi di altre componenti aeronautiche, offrendo un metodo generale per il monitoraggio e l'ottimizzazione dei processi produttivi attraverso un sistema avanzato e data-driven.

# Indice

$\mathbf{E}$	lenco	delle figure	VIII	
$\mathbf{E}$	lenco	delle tabelle	XI	
1	Intr	oduzione	1	
	1.1	Contesto e motivazioni	1	
	1.2	Executive Summary	2	
	1.3	Analisi predittiva nell'industria	3	
		1.3.1 Esempi in letteratura	5	
	1.4	Struttura dell'elaborato	6	
2	Arc	hitettura del rotore principale e componenti di controllo	7	
	2.1	Controllo del rotore principale	7	
	2.2	Main Rotor Actuator	12	
		2.2.1 Main Control Valve	14	
3	Modello fisico della valvola di controllo			
	3.1	Classificazione delle valvole di controllo	16	
	3.2	Portata attraverso un orifizio	18	
		3.2.1 Flusso Potenziale	19	
	3.3	Flusso di Hagen-Poiseuille	21	
	3.4	Aree di passaggio	23	

		3.4.1	Gioco radiale equivalente	23
		3.4.2	Calcolo dell'area di passaggio	25
	3.5	Config	gurazione e funzionamento della valvola	26
	3.6	Analis	si dinamica del servosistema	28
	3.7	Prove	di portata e pressione	35
		3.7.1	Flow Gain nel banco prova	35
		3.7.2	Pressure Gain	37
4	Imp	olemen	tazione	40
	4.1	Model	llo Simulink	40
		4.1.1	Modellazione degli orifizi	43
	4.2	Simula	azione del test Flow Gain	46
	4.3	Valida	zione del modello	48
		4.3.1	Modello Pressure Gain	48
		4.3.2	Modello Flow Gain	51
	4.4	Stima	dei parametri incogniti	53
		4.4.1	Elaborazione dei dati grezzi	53
		4.4.2	Estrazione preliminare dei parametri	55
		4.4.3	Identificazione della valvola	57
		4.4.4	Problema di ottimizzazione	58
	4.5	Perfor	mance del modello	59
5	Mac	chine I	Learning	63
	5.1	Introd	luzione al Machine Learning	63
	5.2	Parad	igmi di apprendimento	64
		5.2.1	Supervised Learning	65
		5.2.2	Unsupervised Learning	66
		5.2.3	Reinforcement Learning	66
	5.3	Applie	cazioni al caso studio	67

		5.3.1	Anomaly detection tramite unsupervised learning	68
		5.3.2	Regressione per la stima dei parametri delle valvole	75
		5.3.3	Deep Learning per prevenire derive nel processo produttivo .	87
6	Cor	nclusio	ni	102
	6.1	Risult	ati ottenuti	103
	6.2	Applie	cazioni future	104
		6.2.1	Evoluzione del modello simulativo	105
		6.2.2	Applicazioni dell'analisi con autoapprendimento	105
$\mathbf{R}^{\mathbf{i}}$	iferin	nenti l	pibliografici	106

# Elenco delle figure

2.1	Hub del rotore (MBB Bo $105)$	8
2.2	Cabina di pilotaggio (AW169)	9
2.3	Comando collettivo e ciclico rispetto al piano di controllo $[19]$	11
2.4	Schema di controllo idraulico di un MRA	13
2.5	Sezione della Main Control Valve	15
3.1	Possibili costruzioni per i centri	17
3.2	Guadagno in portata con le possibili configurazioni dei centri	18
3.3	Efflusso attraverso un orifizio (vena contracta)	20
3.4	Sezione anulare	22
3.5	Gioco radiale equivalente tra cassetto e camicia intermedia	24
3.6	Aree di passaggio	25
3.7	Rappresentazione schematica della valvola	27
3.8	Circuito idraulico equivalente	27
3.9	Rappresentazione 3D di un MRA	28
3.10	Cilindro Idraulico	29
3.11	Feedback Meccanico	32
3.12	Diagramma a blocchi del servosistema	32
3.13	Diagramma di Bode del servosistema in catena aperta	34
3.14	Configurazione della valvola per il test Flow Gain	36
3.15	Confronto tra configurazione overlap, critica e underlap	37

3.16	Configurazione della valvola per il test Pressure Gain	38
3.17	grafici di Pressure Gain e Leakage flow	39
4.1	Curve di Portata	41
4.2	Effetto della lunghezza d'ingresso sul coefficiente di efflusso	45
4.3	Schema a blocchi per la simulazione di un orifizio	47
4.4	Configurazione test $Flow~Gain$ del modello di simulazione	48
4.5	Confronto tra varie simulazioni della prova Flow Gain	49
4.6	Configurazione test $Pressure\ Gain\ del modello\ di\ simulazione\ .\ .\ .$	50
4.7	Confronto con modello pre esistente - Pressure Gain	51
4.8	Configurazione test $Flow~Gain$ del modello di simulazione	52
4.9	Confronto con modello pre esistente - Pressure Gain	53
4.10	Plot dei dati sperimentali prima e dopo l'elaborazione preliminare .	54
4.11	Curve di Portata	56
4.12	Stima dei parametri dalla geometria delle curve di portata	57
4.13	Tool Parameter Estimator di Simulink	59
4.14	Confronto tra prove sperimentali e modello simulato	60
4.15	Evoluzione dei parametri di ottimizzazione nel tempo	62
5.1	Paradigmi dell'apprendimento automatico	64
5.2	Algoritmo Isolation Forest	69
5.3	Istogramma delle occorrenze per anomaly score	72
5.4	Grafico 3D delle curve di portata in funzione del punteggio di anomalia $$	73
5.5	Esempio grafici con diversi anomaly score	74
5.6	Esempi di grafici con anomaly score calcolati sulle differenze $\ \ldots \ \ldots$	75
5.7	Marginalizzazione e condizionamento	77
5.8	Esempi di strutture ottenibili da diversi kernel	78
5.9	Validazione delle predizioni di zero idraulico e ricoprimento nel da-	
	taget sintetico	82

5.10	Predizioni di zero idraulico e ricoprimento con modello addestrato	
	su dati sintetici	83
5.11	Distribuzione dell'errore relativo di zero idraulico e ricoprimento con	
	modello addestrato su dati sintetici	83
5.12	Predizioni di zero idraulico e ricoprimento con modello addestrato	
	su dati reali	85
5.13	Distribuzione dell'errore relativo di zero idraulico e ricoprimento con	
	modello addestrato su dati reali	85
5.14	Rete neurale artificiale	88
5.15	Rappresentazione di una cella LSTM	89
5.16	Forecasting con rete LSTM	93
5.17	Forecasting con rete a due livelli LSTM	94
5.18	Forecasting con rete biLSTM	95
5.19	Forecasting con rete biLSTM (simmetria)	95
5.20	Componenti della serie temporale sintetica	97
5.21	Forecasting della serie sintetica con rete LSTM	98
5.22	Forecasting a due livelli LSTM (finestra temporale ridotta)	99
5.23	Forecasting a due livelli LSTM (finestra temporale più larga)	99
5.24	Forecasting della serie sintetica con rete biLSTM	100

# Elenco delle tabelle

4.1	Comparazione con modello pre esistente - Pressure Gain	51
4.2	Comparazione con modello preesistente - Flow Gain	52
4.3	Metriche di valutazione del modello per i diversi esperimenti	61
5.1	Output Isolation Forest	72
5.2	RMSE delle predizioni su un set di validazione	76
5.3	Output della funzione predict per un modello GPR (fitrgp)	81
5.4	Performance del modello con varie inclusioni di dati reali	87
5.5	Confronto tra le architetture LSTM utilizzate	92

# Capitolo 1

# Introduzione

### 1.1 Contesto e motivazioni

Lo scopo del progetto di tesi è studiare e creare un framework innovativo per l'analisi della produzione delle Main Control Valves del Main Control Actuator dell'elicottero AW169. Le valvole idrauliche nel settore aeronautico richiedono tolleranze produttive estremamente strette: minime deviazioni nei parametri di produzione possono comprometterne irrimediabilmente le prestazioni. L'obiettivo è integrare strategie di modellazione physical-based e componenti di Machine Learning per estrarre informazioni rilevanti dai test di portata condotti in fase di produzione.

L'analisi approfondita di questi dati permette di identificare trend nascosti, correlazioni tra parametri di processo e derive statistiche indicative di criticità produttive. Inoltre, consente di individuare tendenze negative (ad esempio, variabilità anomala tra lotti) e focalizzare la ricerca delle cause radice, come l'usura degli utensili o variazioni nei materiali, prima che le conseguenze sulla produzione diventino irreversibili.

La sinergia tra modello fisico, calibrato sui dati sperimentali, e algoritmi di apprendimento automatico trasforma i test di portata in uno strumento diagnostico proattivo. Questo approccio abilita un controllo qualità predittivo, allineato ai

principi dell'Industria 4.0, riducendo il rischio di immettere componenti non conformi, ottimizzando l'efficienza produttiva e, non ultimo, contribuendo alla sicurezza aeronautica attraverso un monitoraggio data-driven dell'intera catena del valore.

### 1.2 Executive Summary

L'industria aeronautica ricerca costantemente soluzioni innovative per migliorare l'affidabilità e l'efficienza dei componenti. Questa tesi sviluppa un modello numerico per la simulazione della Main Control Valve (MCV) dell'attuatore del rotore dell'elicottero AW169, con l'obiettivo di supportare il controllo qualità e l'analisi dei parametri produttivi.

L'approccio adottato combina modellazione fisico-matematica, simulazioni in MATLAB Simulink e machine learning per estrarre informazioni dai test idraulici e stimare parametri geometrici non direttamente misurabili. Il modello, basato sulle equazioni di flusso attraverso orifizi e sezioni anulari, si è dimostrato affidabile nel replicare il comportamento della valvola. Parallelamente, algoritmi di unsupervised learning sono stati impiegati per identificare anomalie nei test, mentre modelli di regressione e reti neurali hanno permesso la previsione di parametri critici, permettendo nuove strategie di monitoraggio intelligente.

I risultati confermano il potenziale dell'integrazione tra simulazione e machine learning nel miglioramento della qualità e nella riduzione delle non conformità. Le prospettive future includono l'integrazione del modello in simulazioni complete del servomeccanismo e lo sviluppo di strumenti per la manutenzione e prognostica adattiva.

### 1.3 Analisi predittiva nell'industria

L'utilizzo di analisi predittiva nell'industria si collega direttamente agli obiettivi descritti nella sezione precedente: integrare modelli fisici e algoritmi di apprendimento automatico per identificare anomalie e intervenire tempestivamente. Questo approccio è particolarmente utile nel contesto della manutenzione industriale, dove l'efficienza operativa e la riduzione dei costi rappresentano obiettivi primari [15, 6].

Le strategie di manutenzione industriale possono essere classificate in quattro categorie principali, secondo la norma ISO 13306:2010:

### • Manutenzione correttiva (Corrective or Reactionary Maintenance)

In questo approccio, l'attività di manutenzione interviene solo dopo il guasto, con l'obiettivo di ripristinare rapidamente il funzionamento del sistema. La manutenzione correttiva è anche nota come manutenzione run-to-failure, in quanto non si compiono interventi preventivi. Secondo la norma, la manutenzione correttiva è eseguita dopo il riconoscimento del guasto e mira a riportare il componente in uno stato in cui possa svolgere la funzione richiesta. È la forma di manutenzione più semplice, tuttavia, è la meno efficace in termini di costi, poiché comporta periodi di fermo non programmati e costosi interventi di riparazione.

### • Manutenzione preventiva (Preventive Maintenance)

La manutenzione preventiva mira a prevenire i guasti eseguendo attività di manutenzione a intervalli prestabiliti o secondo criteri specifici. La manutenzione preventiva è eseguita a intervalli predeterminati per ridurre la probabilità di guasto o il degrado delle prestazioni di un componente. Questo approccio prevede attività come ispezioni, sostituzioni e regolazioni programmate. Sebbene riduca la probabilità di guasti, può comportare interventi non necessari se non pianificato correttamente, risultando in costi aggiuntivi.

### • Manutenzione proattiva per l'affidabilità (*Proactive Reliability Main*tenance)

Questo approccio si concentra sull'identificazione e l'eliminazione delle cause alla base dei guasti, cercando di evitare che si verifichino interruzioni nei servizi. La manutenzione proattiva raccoglie misure, esegue azioni correttive e identifica i difetti prima che si verifichino guasti. Può essere realizzata mentre il componente è in funzione, riducendo il rischio di malfunzionamenti e ottimizzando l'affidabilità complessiva del sistema.

# • Manutenzione basata sulle condizioni (Condition-Based Maintenan-ce)

La manutenzione basata sulle condizioni si basa sul monitoraggio in tempo reale dei segnali provenienti dai sensori per identificare anomalie e risolverle prima che si verifichi un guasto funzionale. La manutenzione viene effettuata solo quando i dati provenienti dal monitoraggio indicano un problema, evitando interventi prematuri o inutili. Questa tecnica preventiva combina il monitoraggio delle condizioni, dei test e l'analisi dei dati per scegliere le azioni di manutenzione necessarie. Questo approccio consente di intervenire in modo mirato e tempestivo, riducendo il rischio di guasti improvvisi e ottimizzando i costi di manutenzione.

Le ultime due categorie rientrano pienamente nelle strategie di manutenzione predittiva e fanno utilizzo dei big data per migliorare la produzione e monitorare i prodotti. Questo lavoro di tesi permette di avvicinarsi a questi obiettivi, offrendo un contributo significativo all'ottimizzazione dei processi produttivi, evidenziando il valore dell'integrazione di soluzioni data-driven nelle pratiche industriali.

### 1.3.1 Esempi in letteratura

In letteratura esistono numerosi esempi di applicazioni dell'analisi predittiva mirate a migliorare l'affidabilità della produzione e a ottimizzare i processi industriali. Le tecniche di analisi predittiva trovano impiego sia nella manutenzione predittiva che nel controllo di qualità della produzione, sfruttando modelli basati su dati per identificare anomalie, prevedere guasti e ottimizzare le prestazioni dei sistemi.

Un esempio significativo è presentato da Gonzalez-Jimenez et al. [7], che hanno sviluppato una strategia basata su apprendimento automatico per diagnosticare guasti nei motori a induzione. Poiché i dati reali relativi a guasti specifici sono spesso limitati, gli autori hanno utilizzato simulazioni *Software-in-the-Loop* per generare i dataset "fittizi" per l'addestramento dei modelli. Il metodo è risultato efficace per prevenire errori umani e migliorare la manutenzione.

Xiong et al. [23] hanno studiato un'infrastruttura per la manutenzione intelligente dei motori aeronautici, guidato dal concetto di *Digital Twin*. Utilizzando gemello digitale e tecniche di *Deep Learning* hanno dimostrato che combinare modelli basati sui dati con analisi virtuali consente di prevedere con alta precisione la vita utile dei motori aeronautici. I risultati sperimentali hanno evidenziato un errore RMSE basso, migliore rispetto ad altre soluzioni testate, confermando l'efficacia del metodo nel garantire sicurezza operativa e ridurre i costi di gestione.

Un altro contributo rilevante è offerto da Li et al. [11], che hanno sfruttato tecnologie basate sui dati per la stima dello stato di salute e la previsione della durata
delle batterie al litio, cruciali per i veicoli elettrici. Gli autori hanno esaminato
metodi analitici e approcci di *Machine Learning*, evidenziandone vantaggi, limiti
e sfide pratiche. Questo lavoro ha mostrato come il monitoraggio predittivo possa
ridurre i costi, prevenire malfunzionamenti e facilitare il miglioramento dei sistemi
di gestione delle batterie.

### 1.4 Struttura dell'elaborato

Il presente elaborato si articola in quattro capitoli principali, oltre a questa introduzione.

Il primo capitolo offre una panoramica sul problema del controllo del rotore negli elicotteri, fornendo una sintesi dei principi di meccanica del volo e una descrizione dei componenti chiave del sistema di controllo. Particolare attenzione viene dedicata al *Main Rotor Actuator* (MCA) e alla *Main Control Valve* (MCV), oggetto principale di questa ricerca, per evidenziarne il ruolo cruciale nel garantire la precisione e la qualità della realizzazione.

Il secondo capitolo si concentra sulla formulazione matematica adottata per simulare il comportamento idraulico della valvola. Vengono descritte le ipotesi di base, le equazioni fondamentali e i criteri utilizzati per rappresentare il modello fisico di interesse.

Il terzo capitolo tratta dell'implementazione del modello matematico nell'ambiente MATLAB/Simulink. Viene descritta la costruzione del modello a blocchi e del codice computazionale, con particolare enfasi sulla validazione dei risultati e sull'affidabilità predittiva del modello.

Il quarto capitolo introduce i concetti fondamentali dell'apprendimento automatico, illustrando come questi siano stati applicati all'analisi dei dati sperimentali provenienti dalle prove idrauliche della valvola. Sono presentati alcuni esempi di come sia possibile utilizzare algoritmi di *Machine Learning* per effettuare analisi di dati di produzione ed ottenere *insights* e previsioni.

L'elaborato si conclude con una sezione finale dedicata alle considerazioni complessive sul lavoro svolto e alle prospettive di sviluppo futuro, sia dal punto di vista delle applicazioni industriali che degli avanzamenti teorici.

# Capitolo 2

# Architettura del rotore principale e componenti di controllo

### 2.1 Controllo del rotore principale

Prima di concentrarsi sull'analisi del componente analizzato, i.e la Main Control Valve, è bene dare un po' di contesto sul controllo del rotore principale degli elicotteri. L'azione di controllo di un elicottero in volo si concentra principalmente sulla regolazione della spinta del rotore principale, sia in termini di intensità che di direzione [19]. La difficoltà principale nel controllo degli elicotteri risiede nel modificare la direzione della spinta. Si potrebbe, teoricamente, inclinare l'asse del rotore rispetto alla fusoliera. Tuttavia, negli elicotteri, a differenza dei girocotteri, l'asse del rotore è azionato da un motore e le forti forze giroscopiche rendono questa operazione complessa e poco pratica. La soluzione più efficace per gestire il controllo della spinta risulta essere il feathering, che consiste nel variare l'angolo di attacco delle pale del rotore.

Il sistema più comune e performante per ottenere questo effetto è il piatto oscillante, o *swash plate*, che consente una regolazione dinamica dell'angolo di attacco durante la rotazione del rotore, garantendo un controllo ottimale in volo.

Lo swash plate permette di variare l'angolo di attacco delle pale del rotore durante la loro rotazione consentendo al pilota di controllare la direzione del volo e la portanza complessiva. Si può osservare il meccanismo in figura 2.1.



Figura 2.1: Hub del rotore (MBB Bo 105)

La struttura è composta da due sezioni principali: la parte inferiore che ospita il piatto fisso e quella superiore che ospita il piatto rotante. Il piatto fisso è collegato ai comandi del pilota in cabina, mentre quello rotante è connesso, tramite aste di collegamento, alle pale. Il piatto rotante si muove liberamente con il mozzo del motore ed è collegato al piatto fisso tramite cuscinetti.

I comandi azionati dal pilota sono quelli relativi al ciclico e collettivo. Quando il pilota aziona la leva del collettivo il piatto fisso si alza o abbassa in modo uniforme. Questo movimento si riflette nel piatto rotante che varia simultaneamente l'angolo di attacco di tutte le pale del rotore. Variando l'angolo di attacco in questo modo,

si modifica la portanza dell'elicottero, permettendogli di salire o scendere di quota. Attraverso il comando ciclico, invece, il piatto fisso si inclina in una determinata direzione. Il piatto rotante, in maniera analoga, trasmette questa variazione di angolo alle pale variando l'angolo di attacco di ciascuna pala in maniera differenziale durante il ciclo di rotazione. Questo movimento permette all'elicottero di muoversi avanti, indietro o lateralmente.



Figura 2.2: Cabina di pilotaggio (AW169)

La figura 2.2 mostra la cabina di pilotaggio di un elicottero. La leva del passo collettivo si trova in basso alla sinistra del pilota (sedile destro); Il joystick dei comandi ciclici si trova davanti tra le ginocchia. La pedaliera (anti-torque pedals) controlla l'angolo di attacco delle pale, e quindi la spinta, del rotore di coda. Lo scopo è quello di bilanciare la coppia del rotore principale o cambiare la direzione dell'aeromobile.

Il passo ciclico imposta un angolo di attacco variabile con l'angolo azimutale <sup>1</sup> rispetto al piano normale all'asse del mozzo. Questa variazione è ciclica, pertanto è possibile descriverla con una serie di Fourier:

<sup>&</sup>lt;sup>1</sup>i.e. posizione angolare della pala mentre ruota attorno al mozzo

$$\theta = \theta_0 - A_1 \cos \psi - B_1 \sin \psi - A_2 \cos 2\psi - B_2 \sin 2\psi \dots \tag{2.1}$$

All'atto pratico si tronca la serie ai primi termini armonici. Si ottiene:

$$\theta = \theta_0 - A_1 \cos \psi - B_1 \sin \psi \tag{2.2}$$

dove:

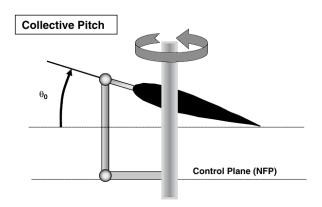
- 1.  $\theta_0$  rappresenta il pitch collettivo.
- 2.  $\psi$  è l'angolo azimutale.
- 3.  $A_1$  è il coefficiente ciclico laterale. Esso applica la massima variazione per angoli azimutali di 0° e 180°. È detto coefficiente laterale perché la risposta del rotore è in ritardo di 90° rispetto all'azione di controllo.
- 4.  $B_1$  è il coefficiente ciclico longitudinale.

La relazione tra angolo di attacco e forza aerodinamica viene modellizzata attraverso le equazioni fondamentali della teoria del disco rotante, [17]. Per una sezione elementare di pala di lunghezza dr a distanza radiale r dal mozzo, la portanza per unità di lunghezza è espressa da:

$$L' = \frac{1}{2}\rho v_{\rm rel}^2 cC_l \tag{2.3}$$

dove:

- $\rho$ : densità dell'aria [kg/m<sup>3</sup>]
- $v_{\rm rel} = \sqrt{(\Omega r)^2 + (v_i + V \sin \psi)^2}$ : velocità relativa risultante, combinazione della componente rotazionale  $\Omega r$  (con  $\Omega$  velocità angolare del rotore) e della velocità indotta  $v_i$  dovuta al flusso attraverso il disco
- c: corda aerodinamica della pala [m]



(a) passo collettivo

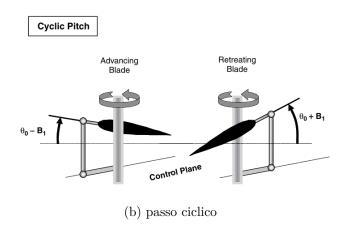


Figura 2.3: Comando collettivo e ciclico rispetto al piano di controllo [19]

•  $C_l = a\alpha$ : coefficiente di portanza lineare, valido per piccoli angoli di attacco (a dipende dalla forma del profilo dell'elica)

L'angolo di attacco effettivo  $\alpha$  risulta dalla differenza tra il passo geometrico  $\theta$  (impostato meccanicamente dal piatto oscillante) e l'angolo di influsso  $\phi$  generato dal flusso aerodinamico:

$$\alpha = \theta - \phi = \theta - \arctan\left(\frac{v_i + V\sin\psi}{\Omega r}\right)$$
 (2.4)

dove:

ullet V: velocità di avanzamento dell'elicottero

•  $\psi$ : angolo azimutale della pala

Integrando l'equazione (2.3) lungo tutta la pala e mediando su un giro completo, si ottiene l'espressione classica della spinta totale in hovering (condizione a velocità di avanzamento nulla V = 0):

$$T = \frac{N_b}{2} \rho a c \Omega^2 R^3 \left( \frac{\theta_0}{2} - \frac{3}{4} \lambda \right) \tag{2.5}$$

dove:

- $N_b$ : numero di pale del rotore
- R: raggio del rotore [m]
- $\lambda = v_i/\Omega R$ : rapporto di influsso
- $\theta_0$ : passo collettivo definito nell'Equazione (2.2)

L'Equazione (2.5) dimostra come il controllo collettivo ( $\theta_0$ ) regoli direttamente la spinta verticale. I termini ciclici  $A_1$  e  $B_1$  dell'Equazione (2.2) inducono invece variazioni armoniche della portanza che inclinano il disco rotore, orientando la spinta per il controllo direzionale. Questo effetto manifesta un ritardo di fase di 90° dovuto alla precessione giroscopica del rotore, fenomeno fondamentale nella dinamica elicotteristica.

### 2.2 Main Rotor Actuator

Durante il volo, i requisiti di prontezza e accuratezza richiesti, oltre agli elevati carichi dinamici, rendono spesso necessario l'utilizzo di sistemi idraulici <sup>2</sup>. Nel rotore

 $<sup>^2{\</sup>rm In}$ aeromobili di piccola taglia sono possibili controlli puramente meccanici, senza amplificazione della forza del pilota

principale, il piatto fisso - dotato di tre gradi di libertà (collettivo, ciclico longitudinale e ciclico laterale) - è controllato da tre martinetti idraulici lineari, collegati ad altrettanti servoattuatori detti MRA (*Main Rotor Actuator*).

Il funzionamento generale di un MRA [16] viene esaminato, con uno schema rappresentativo visibile in figura 2.4. Gli elementi di potenza collegati al control rod (martinetto) sono costituiti da una coppia di cilindri montati in tandem (tandem hydraulic actuator). L'interfaccia di comando è affidata a due servovalvole (main control valve), ciascuna delle quali regola il flusso del liquido nelle camere antagoniste dei cilindri.

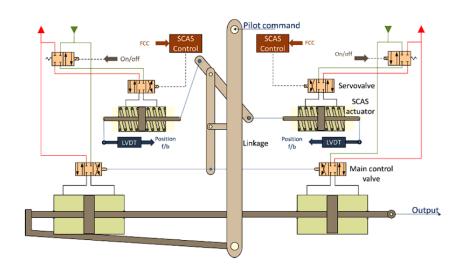


Figura 2.4: Schema di controllo idraulico di un MRA

Il movimento del cassetto all'interno delle valvole, che determina la direzione e la portata del fluido, è pilotato da un sistema di leveraggi collegato al nodo di somma meccanico. La posizione di questo punto di controllo varia in funzione di tre ingressi:

- Comando primario del pilota (via collegamento meccanico o fly-by-wire)
- Feedback positivo dalla posizione dell'attuatore (sistema di chiusura del loop)

• Correzione attiva da due attuatori SCAS (Stabilization and Command Augmentation System).

Il sistema SCAS è necessario ad aumentare la stabilità dell'elicottero in volo, sommando all'input del pilota un'azione di controllo che deriva da sistemi di elaborazione provenienti dal computer di controllo di volo basato su dati di giroscopi, accelerometri e sensori di carico. Gli attuatori dello SCAS sono controllati da due HSV (Hydraulic Servo Valve) e da due SOV (Shut off Valve). La HSV riceve in input il segnale in tensione e lo traduce in una portata idraulica, mentre la valvola di shut off è necessaria per interrompere l'azione dello SCAS quando non necessaria o in condizioni di guasto. I componenti, seguendo la filosofia tipica delle costruzioni aerospaziali, sono ridondanti.

### 2.2.1 Main Control Valve

La valvola di controllo principale (*Main Control Valve*), componente cardine dell'analisi condotta in questo elaborato, è un dispositivo idraulico direzionale a cassetto scorrevole (*spool*) con azionamento meccanico e ridondanza integrata. La sua funzione primaria è tradurre i comandi meccanici del sistema di controllo in variazioni di portata/pressione per governare gli attuatori idraulici del rotore principale. La valvola è composta da tre componenti fondamentali (Figura 2.5):

- Spool (cassetto): elemento mobile che regola l'apertura dei canali idraulici mediante movimento assiale
- Sleeve (camicia intermedia): guida statica che indirizza il flusso del fluido attraverso i condotti di alimentazione e scarico
- Body (corpo esterno): struttura contenitiva che integra le connessioni al circuito idraulico

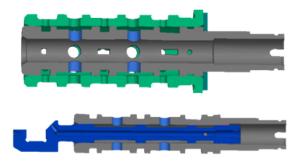


Figura 2.5: Sezione della Main Control Valve

La valvola integra un meccanismo passivo di emergenza che entra in funzione in caso di ostruzione meccanica del cassetto o di una eccessiva resistenza al movimento. In queste condizioni, l'intero gruppo cassetto-camicia può traslare in maniera solidale vincendo la resistenza di una molla calibrata detta *anti-jamming spring*.

# Capitolo 3

# Modello fisico della valvola di controllo

### 3.1 Classificazione delle valvole di controllo

Le valvole di controllo idrauliche sono dispositivi che utilizzano il movimento meccanico per controllare una fonte di potenza fluida all'interno di un sistema attuato. Tra le valvole di controllo, le più comuni sono quelle a cassetto composte da un corpo esterno e un organo mobile dotato di colletti di controllo diametrali (spool), che occlude o scopre le luci di controllo, regolando il flusso del fluido che passa attraverso il componente. La Main Control Valve del Main Control Actuator è la valvola analizzata in questo capitolo e rientra in questa categoria.

Le valvole a cassetto possono essere classificate in base a:

- 1. Il numero di vie con le quali il flusso può attraversare la valvola;
- 2. Il numero di zone di controllo diametrali (lands);
- 3. Il tipo di centro quando la valvola è in posizione neutra.

La valvola analizzata è del tipo a 4 vie e 3 spallamenti.

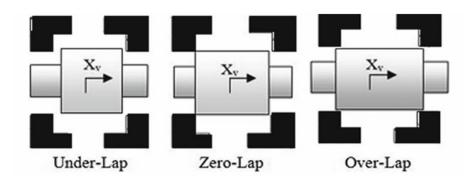


Figura 3.1: Possibili costruzioni per i centri

Per quanto riguarda il tipo di centro, si possono realizzare tre costruzioni: centri critici, centri aperti e centri chiusi. Per centro critico o a lappatura zero si intende una realizzazione per cui la larghezza del land è pari alla larghezza della porta. In una valvola a cassetto a centro chiuso, il ricoprimento della tenuta è maggiore della luce di passaggio. Il nome centro chiuso, infatti, deriva dal fatto che con questa costruzione le porte di alimentazione e scarico non sono mai messe in collegamento durante la commutazione. Viceversa, il centro aperto, anche detto underlap, è una costruzione che prevede una dimensione del ricoprimento minore rispetto a quella della luce della porta. In questo caso, quando la valvola si trova in prossimità dello zero idraulico, le porte di supply e return sono messe in collegamento diretto. Quest'ultima configurazione, seppur aumentando le perdite, è quella preferita per componenti che necessitano tempi di risposta molto ridotti. Difatti, la MCV dell'MRA è realizzata in questa configurazione.

Come si può osservare dal grafico 3.2, la configurazione a centri chiusi presenta una zona morta. Quest'ultima può provocare errori allo stato stazionario, non accettabili nei problemi di controllo più complessi come quelli del controllo del rotore primario di un elicottero.

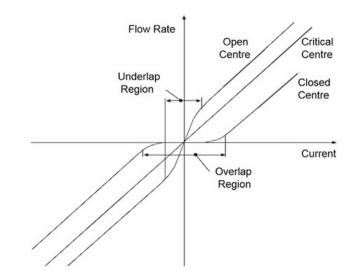


Figura 3.2: Guadagno in portata con le possibili configurazioni dei centri

### 3.2 Portata attraverso un orifizio

L'orifizio è un'apertura o un foro, generalmente di dimensioni note, attraverso il quale può passare un fluido. Sono essenziali per la modellazione matematica della valvola, in quanto essa è schematizzata come un circuito idraulico di orifizi di dimensioni sia fisse che variabili. Il fluido, attraverso un orifizio, può comportarsi in maniera differente a seconda delle forze che dominano il regime di efflusso. Il regime dipende dalle forze dominanti sul fluido, che possono essere viscose o d'inerzia. Il discriminante è, ovviamente, il numero di Reynolds Re.

Re è un numero adimensionale e rappresenta il rapporto tra le forze inerziali e le forze viscose che agiscono sul fluido.

$$Re = \frac{vD_h}{\nu} \tag{3.1}$$

dove:

1. v è la velocità di flusso locale (m/s), generalmente calcolata come rapporto tra:

- (a) Q: la portata volumetrica  $(m^3/s)$ ;
- (b) A: l'area di passaggio  $(m^2)$
- 2.  $D_h$  diametro idraulico, la lunghezza caratteristica del fenomeno (m);
- 3.  $\nu$  è la viscosità cinematica  $(m^2/s)$  pari al rapporto tra:
  - (a)  $\mu$ : la viscosità dinamica  $(kg/(m \cdot s))$ ;
  - (b)  $\rho$ : la densità (o massa volumica)  $(kg/m^3)$

Con numeri di Reynolds elevati, la caduta di pressione che avviene attraverso l'orifizio è causata dall'accelerazione delle particelle fluide che devono modificare la loro velocità per soddisfare la legge di continuità. A bassi Reynolds, la caduta di pressione è maggiormente influenzata dalle forze di taglio presenti a causa della viscosità del fluido.

### 3.2.1 Flusso Potenziale

La maggior parte dei fenomeni che coinvolgono gli orifizi avvengono a numeri di Reynolds elevati. Questo tipo di efflusso viene normalmente definito turbolento, ma si tratta di un fenomeno distinto rispetto al flusso turbolento che è possibile incontrare, ad esempio, nel moto in condotti.

L'efflusso dominato dalle forze d'inerzia è detto turbolento perché caratterizzato da moto irregolare e vorticoso delle particelle del fluido. In alcuni casi, come quello dell'orifizio, la viscosità è influente solo nello strato limite (boundary layer), in prossimità di pareti solide. Il flusso al di fuori dello strato limite è soggetto soprattutto all'inerzia ma si comporta in maniera ordinata, simile a quella del regime laminare. Se lo strato limite rappresenta una parte limitata del dominio, si può trascurare la sua influenza. In questo caso si parla di flusso potenziale (potential o streamline flow). A differenza del flusso turbolento, che si descrive conn relazioni empiriche,

il flusso potenziale sfrutta l'equazione di Bernoulli (sotto ipotesi di stazionarietà, incomprimibilità e assenza di attrito):

$$\frac{P}{\gamma} + \frac{v^2}{2g} = costante \tag{3.2}$$

Quando un fluido attraversa un orifizio, le linee di flusso si contraggono a causa dell'inerzia del fluido, che tende a seguire traiettorie convergenti mentre passa attraverso l'orifizio. Il punto in cui la sezione è minima è detto vena contracta. È possibile legare l'area dell'orifizio  $A_0$  a quella della sezione contratta  $A_1$  tramite il coefficiente di contrazione  $C_c$ :

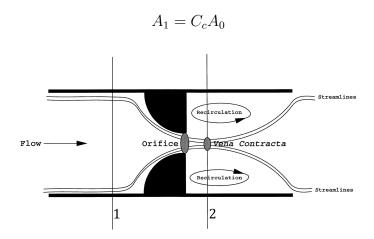


Figura 3.3: Efflusso attraverso un orifizio (vena contracta)

La differenza di pressione necessaria ad accelerare il fluido può essere ricavata applicando la legge di Bernoulli tra i punti 1 e 2:

$$v_2^2 - v_1^2 = \frac{2}{\rho}(P_1 - P_2)$$

Applicando la legge di continuità per i fluidi incomprimibili:

$$Q = A_1 v_1 = A_2 v_2$$

Si ricava la velocità di efflusso in corrispondenza della vena contracta:

$$v_2 = \frac{1}{\sqrt{1 - \left(\frac{A_2}{A_1}\right)^2}} \sqrt{\frac{2}{\rho}(P_1 - P_2)}$$

A causa dell'attrito viscoso si aggiunge un coefficiente empirico  $C_v$  che tiene conto delle perdite. La portata volumetrica, quindi, si calcola come:

$$Q = \frac{C_v A_2}{\sqrt{1 - \left(\frac{A_2}{A_1}\right)^2}} \sqrt{\frac{2}{\rho} (P_1 - P_2)}$$

Essendo più conveniente utilizzare l'area dell'orifizio  $A_0$ , è possibile utilizzare l'equazione di continuità per ottenere la legge di efflusso attraverso l'orifizio <sup>1</sup>:

$$Q = C_d A_0 \sqrt{\frac{2}{\rho} (P_1 - P_2)}$$
 (3.3)

dove:

$$C_d = \frac{C_v C_c}{\sqrt{1 - C_c^2 (A_0 / A_1)^2}}$$

### 3.3 Flusso di Hagen-Poiseuille

La modellazione del flusso valida per elevati numeri di Reynolds risulta inadeguata per descrivere in modo accurato il comportamento del fluido in tutte le condizioni operative della valvola. Questo è particolarmente vero in presenza di ricoprimento positivo, quando il flusso attraversa una sezione anulare di dimensioni ridotte, dove gli effetti viscosi diventano predominanti e non possono essere trascurati.

In queste condizioni, il flusso è laminare e può essere descritto con precisione utilizzando un'estensione della legge di Hagen-Poiseuille.

<sup>&</sup>lt;sup>1</sup>Come menzionato in precedenza, l'equazione 3.3 è valida solo per flussi stazionari, incomprimibili e con un numeri di Reynolds molto elevati. Tuttavia, nella modellazione queste ipotesi vengono trascurate per semplificare il modello, garantendo comunque un'elevata precisione.

Per derivare la formula utilizzata nel modello, si parte dalle equazioni di Navier-Stokes per i flussi caratterizzati da un basso Re:

$$\mu \nabla^2 \mathbf{v} = \nabla p \tag{3.4}$$

E' possibile esprimere questa equazione in coordinate polari  $(r, \theta)$ , assumendo che la pressione vari lungo l'asse perpendicolare alla sezione (z) e che la velocità del flusso cambi lungo il raggio r:

$$\mu \frac{1}{r} \frac{\partial}{\partial r} \left( r \frac{\partial v}{\partial r} \right) = \frac{\partial p}{\partial z} \tag{3.5}$$

Si modella la sezione anulare come spazio compreso tra due circonferenze di raggio  $r_o$  ed R, disposte in maniera eccentrica con centri a distanza e, come in figura 3.4. Per gap di dimensioni ridotte, la velocità in funzione del raggio vale:

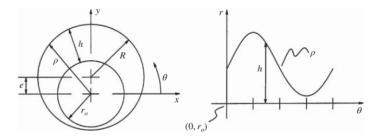


Figura 3.4: Sezione anulare

$$v(r) = -\frac{1}{2\mu} \frac{dp}{dz} (\rho - r)(r - r_0)$$

dove  $\rho = R + \sin(\theta)e$ .

Si ricava la portata volumetrica Q integrando la velocità del flusso sull'area della sezione:

$$Q = \int_A v \ dA = \int_0^{2\pi} \int_{r_0}^{\rho} vr \ dr \ d\theta$$

Si ottiene dunque l'equazione di efflusso attraverso un condotto anulare, necessaria a calcolare le perdite idrauliche che si innescano nella valvola:

$$Q = \frac{\pi R (R - r_0)^3}{6\mu} \frac{\Delta p}{l} \left( 1 + \frac{3}{2} \varepsilon^2 \right)$$
 (3.6)

dove:

- 1.  $\varepsilon$  è il rapporto di eccentricità definito come  $\varepsilon = \frac{e}{R-r_0}$
- 2. l è la lunghezza di passaggio del flusso (m)

È possibile scrivere la formula sostituendo a  $R - r_0$  il gioco radiale equivalente  $h_e$  calcolato come mostrato nel paragrafo successivo.

Se si integra l'equazione solo per parte della circonferenza, nel caso delle valvole per la parte relativa alla larghezza della luce di passaggio w, si ottiene:

$$Q = \frac{\frac{w}{2}h_e^3}{6\mu} \frac{\Delta p}{l} \left( 1 + \frac{3}{2}\varepsilon^2 \right) \tag{3.7}$$

### 3.4 Aree di passaggio

In questo paragrafo si vuole descrivere il metodo utilizzato per stimare la grandezza delle aree di passaggio in funzione dello spostamento del cassetto.

### 3.4.1 Gioco radiale equivalente

Prima di procedere al calcolo delle aree di passaggio è opportuno tenere in considerazione il gioco radiale tra cassetto e camicia intermedia. A causa degli angoli di raccordo, infatti, non va considerato costante, ma è necessario calcolare il valore equivalente in funzione della lunghezza di sovrapposizione z (posizione dello spigolo del cassetto rispetto alla luce). Facendo riferimento alla figura 3.5, si distinguono due casi:

### Caso 1 $z \leq r$

Se il bordo del cassetto è ancora all'interno del raccordo della luce, il gioco equivalente  $h_e$  cambia lungo la sezione curva:

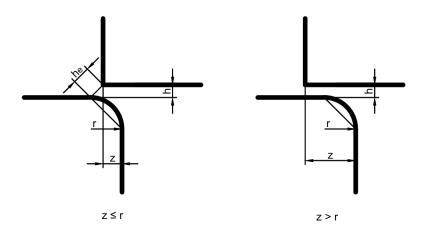


Figura 3.5: Gioco radiale equivalente tra cassetto e camicia intermedia

$$h_e = \sqrt{h^2 + (r - z)^2} \tag{3.8}$$

dove:

- 1.  $h \approx il gioco radiale,$
- 2. r è il raggio di raccordo,
- 3. z è la lunghezza di sovrapposizione è funzione dello spostamento del cassetto x.

L'idea alla base della formula è che il contorno effettivo del passaggio del fluido forma un triangolo rettangolo in cui un cateto è il gioco nominale e l'altro è la differenza tra il raggio di raccordo e la lunghezza di sovrapposizione.

### Caso 2 z > r

Se il cassetto ha superato completamente il raccordo, la geometria si semplifica in quanto la curvatura non è più coinvolta. Il gioco equivalente è uguale a quello nominale:

$$h_e = h (3.9)$$

### 3.4.2 Calcolo dell'area di passaggio

L'area di passaggio è funzione della posizione relativa tra cassetto e camicia. Si distinguono diverse condizioni operative in funzione dello spostamento del cassetto x e della lunghezza di sovrapposizione S. Facendo riferimento alla figura 3.6, si calcola l'area.

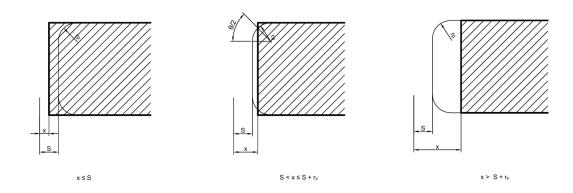


Figura 3.6: Aree di passaggio

### Caso 1 $x \leq S$

nel caso in cui la posizione del cassetto sia tale da coprire completamente la luce di passaggio, l'area di passaggio del fluido si calcola come il rettangolo che ha come lati la larghezza della porta di passaggio (tenendo conto dei raggi di raccordo) e il gioco radiale calcolato in precedenza:

$$A = (w_N - 2r_p)h_e \tag{3.10}$$

- 1.  $w_N$  è la larghezza della porta, e
- 2.  $r_p$  è il raggio di raccordo della porta.

Caso 2 
$$S < x < S + r_p$$

Quando il cassetto raggiunge la regione del raggio di raccordo, l'area di passaggio può essere descritta introducendo  $\theta$  che rappresenta l'angolo di apertura sul raccordo curvo:

$$\theta = 2\arccos\left(1 - \frac{x - S}{r_p}\right) \tag{3.11}$$

L'area di passaggio è obliqua e data dalla composizione del contributo assiale e radiale:

$$A = \sqrt{\left[\left(w_n - 2r_p\right)(x - S) + \frac{r_p^2}{2}(\theta - \sin\theta)\right]^2 + \left[w_n - 2r_p + 2r_p\sin\left(\frac{\theta}{2}\right)\right]^2}$$
 (3.12)

Caso 3 
$$x > S + r_p$$

L'ultimo caso è quello in cui il cassetto supera il raggio di raccordo; in questo caso, la componente assiale dell'area è costante e pari al prodotto tra larghezza della luce e il gioco radiale equivalente, la componente radiale è invece l'area scoperta della porta (figura 3.6).

$$A = \sqrt{\left[ (w_n - 2r_p)r_p + \frac{\pi r_p^2}{2} + w_n(x - S - r_p) \right]^2 + (w_n h_e)^2}$$
 (3.13)

# 3.5 Configurazione e funzionamento della valvola

Dopo aver derivato le formule necessarie per descrivere il comportamento del fluido attraverso orifizi e sezioni anulari, e stabilita la correlazione tra lo spostamento del cassetto e le aree di passaggio del fluido, è possibile sviluppare una modellazione complessiva della valvola.

Ricordando che la valvola è costituita da un cassetto, una camicia intermedia e un corpo esterno (figura 3.7), si possono evidenziare 16 aree di passaggio. Il risultato

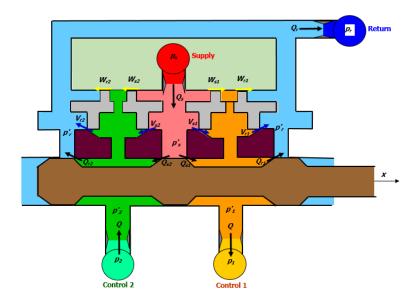


Figura 3.7: Rappresentazione schematica della valvola

è lo schema idraulico che rappresenta il circuito idraulico equivalente composto da ipotetiche valvole a saracinesca che simulano i canali di passaggio del fluido dipendenti dall'area di passaggio, come illustrato in figura 3.8.

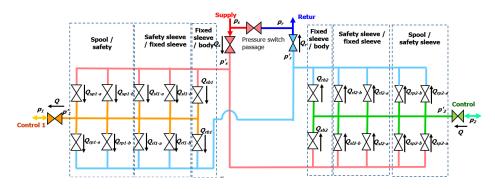


Figura 3.8: Circuito idraulico equivalente

Lo schema sintetizza il funzionamento pratico della valvola. Quando il cassetto si sposta in direzione positiva rispetto alla posizione neutra, la portata verso la porta di controllo 1 aumenta, mentre cresce la portata dalla porta di controllo 2 verso lo scarico. Questa dinamica è rappresentata nel modello attraverso la variazione delle resistenze idrauliche, determinate dall'incremento dell'area di passaggio.

Con uno spostamento positivo del cassetto, aumenta l'area degli orifizi che consentono il passaggio dal canale di alimentazione alla porta di controllo 1, mentre si riduce l'area degli orifizi che permettono il deflusso del fluido dalla porta 1 verso lo scarico. Gli orifizi associati al controllo del fluido attraverso la porta 2 mostrano un comportamento simmetrico: l'area di passaggio verso il ritorno aumenta, mentre diminuisce quella per il flusso dalla porta di alimentazione.

# 3.6 Analisi dinamica del servosistema

Per evidenziare l'importanza delle caratteristiche costruttive della valvola, è fondamentale condurre un'analisi dinamica del servosistema. Si sottolinea come il guadagno in pressione, il guadagno in portata e le perdite influenzino direttamente le prestazioni. Viene riportata una modellazione approssimata del servosistema con alcune ipotesi semplificative.

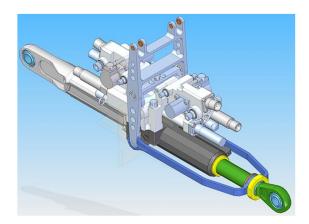


Figura 3.9: Rappresentazione 3D di un MRA

La modellazione del servosistema schematizza le tre parti principali: l'attuatore cilindrico, la Main Control Valve e la leva di somma.

#### Modellazione dell'attuatore cilindrico

Si parte con la modellazione del cilindro idraulico. Questo è un cilindro a doppio effetto con stelo passante, in cui le superfici di spinta sono uguali. Si procede considerando l'equazione di continuità nelle camere:

$$\rho\left(\sum Q_{in} - \sum Q_{out}\right) = \frac{dm}{dt} = \frac{d(\rho V)}{dt} = V\frac{d\rho}{dt} + \rho\frac{dV}{dt}$$
(3.14)

dove:

- 1.  $\rho$  è la densità del fluido,
- 2.  $Q_{in}$  e  $Q_{out}$  sono le portate in ingresso e uscita relative alla camera,
- 3. m è la massa istantanea di fluido presente nella camera.
- 4. V è il volume istantaneo di fluido nella camera.

Introducendo il modulo di bulk (compressibilità del fluido)  $\beta=\rho\frac{\partial p}{\partial \rho}$ , si può scrivere:

$$\left(\sum Q_{in} - \sum Q_{out}\right) = \frac{dm}{dt} = \frac{d(\rho V)}{dt} = \frac{V}{\beta} \frac{dP}{dt} + \frac{dV}{dt}$$
(3.15)

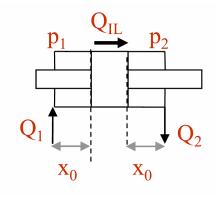


Figura 3.10: Cilindro Idraulico

Se si considera la variazione di volume dovuta allo spostamento dello stelo, per la camera 1 del cilindro vale:

$$Q_1 - Q_{leakage} = A_c \dot{x} + \frac{V_0 + A_c x}{\beta} \frac{dP_1}{dt}$$
(3.16)

dove:

- 1.  $V_0$  è il volume del cilindro in posizione neutra,
- 2. x è lo spostamento dello stelo,
- 3.  $A_c$  è l'area di spinta.

In maniera analoga, per la camera 2 vale:

$$Q_{leakage} - Q_2 = -A_c \dot{x} + \frac{V_0 - A_c x}{\beta} \frac{dP_2}{dt}$$
(3.17)

Combinando le equazioni, ipotizzando che la portata in ingresso e in uscita dalle camere del cilindro sia uguale  $Q_1 = Q_2 = Q_L$  e definendo  $\Delta P_L = P_1 - P_2$ :

$$Q_L - A_c \dot{x} = \frac{V_0}{2\beta} \frac{d}{dt} \Delta P_L \tag{3.18}$$

Trovata la relazione che collega la portata alla differenza di pressione, occorre valutare gli effetti delle forze sul pistone. L'equilibrio delle forze è pari a:

$$\Delta P_L A_C - M\ddot{x} - F_E - \gamma \dot{x} = 0 \tag{3.19}$$

#### Modello lineare della valvola

Per semplificare la trattazione, è possibile linearizzare la funzione della portata attorno a un punto di funzionamento utilizzando lo sviluppo in serie di Taylor. Si ipotizza che la portata in ingresso e in uscita alla valvola e quindi all'attuatore idraulico sia uguale e che dipenda dallo spostamento del cassetto e dalla pressione richiesta dal carico.

$$Q_L = Q_L(A_v, \Delta P_L) \approx \left| Q_{L0} + \frac{\delta Q_L}{\delta x_v} \right|_0 \Delta x_v + \left| \frac{\delta Q_L}{\delta \Delta P_L} \right|_0 \Delta P_L$$
 (3.20)

È possibile introdurre dei coefficienti per descrivere il funzionamento della valvola:

•  $K_Q$  è il coefficiente di portata ( $Flow\ Gain$ ) e misura quanto il flusso idraulico varia in funzione dello spostamento della valvola. Un valore elevato indica che anche piccole variazioni nel comando della valvola producono variazioni significative nel flusso verso l'attuatore

$$K_Q = \left. \frac{\delta Q_L}{\delta x_v} \right|_0 \tag{3.21}$$

•  $K_{PQ}$  è il coefficiente di flusso/portata che indica la variazione di portata in funzione della differenza di pressione di carico sull'attuatore.

$$K_{PQ} = \frac{\delta Q_L}{\delta \Delta P_L} \bigg|_{0} \tag{3.22}$$

•  $K_P$  è il coefficiente di portata che esprime come lo spostamento del cassetto si traduce in una variazione della pressione nelle camere dell'attuatore. Il coefficiente è equivalente al rapporto tra  $K_Q$  e  $K_{PQ}$ 

$$K_P = \left. \frac{\delta \Delta P_L}{\delta x_v} \right|_0 \tag{3.23}$$

I coefficienti possono essere stimati a partire dai test condotti in fase di produzione (sezione 3.7).

#### Leva di somma

La leva di somma è un sottosistema (schematizzato in figura 3.11) che si occupa di creare un feedback meccanico: al segnale di comando del pilota e degli SCAS viene sottratto lo spostamento dell'attuatore. I guadagni dei vari segnali sono legati ai rapporti di leva.

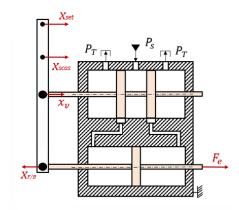


Figura 3.11: Feedback Meccanico

#### Analisi in frequenza del servisistema

Il diagramma a blocchi semplificato del servosistema è riportato in figura 3.12.

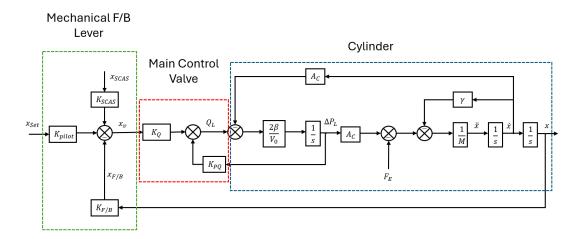


Figura 3.12: Diagramma a blocchi del servosistema

Per valutare la stabilità e le prestazioni dinamiche del servosistema, è utile analizzare la sua funzione di trasferimento in catena aperta, denotata come  $G_{ol}$ . Per fare ciò, si analizza il diagramma di Bode, che consente di studiare la risposta in frequenza del sistema, fornendo informazioni fondamentali sui margini di guadagno

e di fase, sulla banda passante e sulle eventuali risonanze. Il servoattuatore lavora in anello chiuso ed è caratterizzato dal guadagno  $G_{cl}$ :

$$G_{cl} = \frac{G_{ol}}{G_{ol} + 1} \tag{3.24}$$

 $G_{ol}$  è la risposta del sistema in anello aperto, senza considerare la chiusura in retroazione. Dall'analisi della relazione tra  $G_{cl}$  e  $G_{ol}$  risulta evidente perché è necessaria un'attenzione particolare al guadagno in anello aperto. Esso è necessario per valutare la stabilità del sistema; infatti, quando si ha una fase di -180° e un guadagno pari a 1 (0 dB), il sistema in anello chiuso risulta instabile. Questa condizione determina che il denominatore della funzione di trasferimento in catena chiusa si annulli, portando alla presenza di poli con parte reale positiva, causando quindi divergenza o oscillazioni non smorzate.

Per garantire stabilità e robustezza, si analizzano due parametri fondamentali nel diagramma di Bode di  $G_{ol}$ :

- Il margine di fase  $\Phi_m$  è la differenza tra la fase effettiva del sistema quando il guadagno è 0 dB e la soglia di -180°. Se il margine di fase è positivo, il sistema è stabile; se è negativo, si verifica instabilità in anello chiuso. Un margine di fase maggiore implica una maggiore resistenza del sistema a variazioni nei parametri o a disturbi.
- Il margine di guadagno  $G_m$  è l'altro coefficiente che valuta la stabilità ed è misurato calcolando la distanza della risposta dal punto di 0 dB quando la fase è pari a -180°.

#### Effetti delle caratteristiche della MCV

Il coefficiente di flusso  $K_Q$  aumenta il guadagno complessivo dell'anello aperto  $(G_{ol})$  a basse frequenze. Se troppo elevato, può far sì che il guadagno a frequenze critiche (in prossimità del crossover) diventi eccessivo, riducendo il margine di fase.

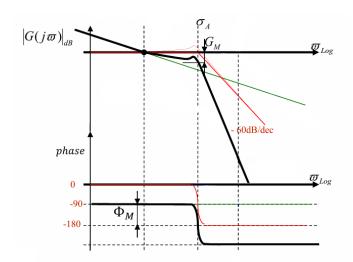


Figura 3.13: Diagramma di Bode del servosistema in catena aperta

La rigidezza statica, ovvero la capacità di mantenere la posizione sotto carico, è influenzata soprattutto dal Pressure Gain  $K_P$ . Un aumento della portata di leakage, rende necessaria una differenza di pressione più elevata per ottenere la stessa portata utile; questo effetto si traduce in una diminuzione di  $K_{PQ}$  e quindi di  $K_P$ . In altre parole, le perdite interne rendono il sistema più sensibile a disturbi e carichi variabili.

 $K_{PQ}$  influenza anche la reattività del sistema e una diminuzione dovuta alle perdite può avere effetti sulle performance del sistema. Tuttavia, se la pressione risponde in maniera troppo aggressiva alle variazioni di carico, il sistema può diventare molto sensibile ai disturbi e subire oscillazioni.

Il valore del ricoprimento, invece, influenza la linearità e la sensibilità del sistema. Un valore di overlap elevato introduce un'ampia zona morta in cui piccole variazioni del comando non producono variazioni nel flusso. Ciò riduce l'effettivo guadagno a bassi segnali. Un overlap ridotto, al contrario, offre una maggiore sensibilità (una risposta anche con segnali di comando ridotti) che migliora la precisione in regime, ma può rendere il sistema più suscettibile a oscillazioni e instabilità se il ritardo di fase è troppo elevato.

# 3.7 Prove di portata e pressione

Durante la costruzione della valvola, e in particolar modo durante la lavorazione del cassetto, è necessario eseguire dei test per verificare la conformità della valvola. Le prove effettuate sulla valvola sono due: la prima è una prova di portata ed è necessaria per valutare il guadagno in portata e verificare se le zone di controllo diametrali hanno una dimensione corretta, la seconda è la prova di pressione che verifica l'assenza di eventuali asimmetrie anomale o perdite elevate e la conformità al progetto del guadagno in pressione.

## 3.7.1 Flow Gain nel banco prova

La prova di portata viene eseguita su un banco di prova idraulico progettato appositamente per testare le *MCV*. Il componente da verificare, ovvero il cassetto della valvola, viene inserito all'interno di una struttura di supporto dotata di sensori e di un attuatore dedicato. I sensori presenti sul banco di prova includono:

- Flussimetri, per misurare la portata del fluido;
- Trasduttori di pressione, per monitorare le pressioni nel circuito idraulico;
- Sensore LVDT, impiegato per rilevare gli spostamenti lineari del cassetto della valvola.

Durante il test, l'attuatore integrato è utilizzato per muovere il cassetto lungo la sua corsa, consentendo di analizzare il comportamento della valvola in funzione dello spostamento del cassetto. La valvola viene alimentata attraverso le porte di controllo, mentre le porte di ritorno e di alimentazione sono connesse allo scarico. Questa configurazione permette di disaccoppiare il comportamento delle due camere di controllo della valvola. Lo schema 3.14 illustra la configurazione di prova della valvola.

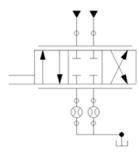


Figura 3.14: Configurazione della valvola per il test Flow Gain

I dati raccolti durante la prova sono registrati automaticamente dal banco di prova e organizzati in file testuali. I dati grezzi sono analizzati nel capitolo 4. Di seguito sono riportati i grafici 3.15 relativi a una valvola in condizione di ricoprimento positivo (overlap), negativo (underlap) e critico, con l'obiettivo di evidenziare le differenze principali tra queste configurazioni.

In figura, la curva blu rappresenta il comportamento relativo alla porta di controllo 1 e la curva rossa alla porta 2. In una valvola ideale le curve sono sovrapposte, ma in quella reale sono presenti delle asimmetrie. Dall'analisi dei grafici emerge che la configurazione di overlap presenta le perdite idrauliche più contenute, in quanto la portata in corrispondenza della posizione neutra del cassetto è minima. Tuttavia, questa configurazione introduce una zona morta, ovvero un intervallo in cui il movimento del cassetto non genera alcuna variazione del flusso, rappresentando uno svantaggio in termini di reattività. La configurazione di ricoprimento critico si distingue per il fatto che la differenza tra la dimensione del ricoprimento del cassetto e quella della luce di passaggio è ridotta al minimo, garantendo un equilibrio ottimale tra precisione e perdite. Infine, la configurazione di underlap produce la risposta più rapida della valvola, poiché anche piccoli spostamenti del cassetto generano variazioni immediate del flusso. Tuttavia, come evidenziato dai grafici, questa configurazione è associata a perdite idrauliche significativamente maggiori rispetto alle altre.

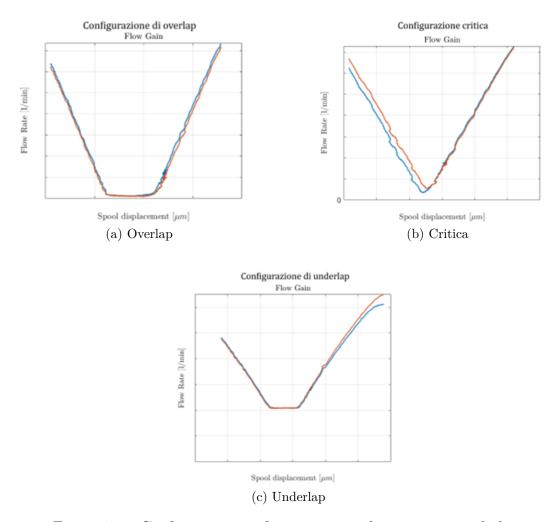


Figura 3.15: Confronto tra configurazione overlap, critica e underlap.

## 3.7.2 Pressure Gain

Sul banco di prova viene eseguita anche la prova di pressione. Durante questo test, dei manometri vengono collegati alle porte di controllo, mentre le porte di alimentazione e scarico sono connesse al circuito idraulico (figura 3.16). Durante lo spostamento del cassetto, effettuato tramite un attuatore, si monitora l'andamento delle pressioni nelle due camere di controllo. Un flussimetro installato sulla luce di alimentazione misura la portata attraversante la valvola, definita leakage flow. Questo valore rappresenta le perdite dovute a giochi radiali o a eventuali ricoprimenti

negativi del cassetto.

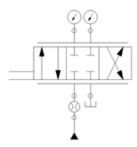


Figura 3.16: Configurazione della valvola per il test Pressure Gain

Rappresentando graficamente i dati (figura 3.17), si osservano le due curve di pressione che mostrano una variazione significativa in corrispondenza dello zero idraulico, ovvero il punto in cui avviene la commutazione della valvola e il flusso cambia direzione. In questa zona, le pressioni nelle due camere di controllo si equivalgono (punto di incrocio delle curve di pressione). La curva della leakage flow assume una forma a campana, con un valore massimo localizzato proprio in prossimità dello zero idraulico. Come evidenziato anche nell'altra prova, nella configurazione di underlap, la portata di leakage raggiunge valori significativamente superiori rispetto ad altre configurazioni. Questo è dovuto alla maggiore apertura delle luci di passaggio (ricoprimento negativo), che riduce le resistenze idrauliche ma aumenta inevitabilmente le perdite.

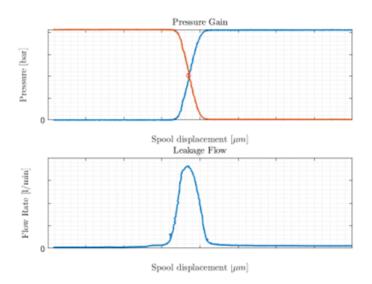


Figura 3.17: grafici di Pressure Gain e Leakage flow

# Capitolo 4

# Implementazione

Il modello matematico descritto nel capitolo 3 è necessario per costruire il codice di calcolo che permette la simulazione della valvola e dei test effettuati su di essa.

Come anticipato, il problema principale della simulazione è quello relativo ai parametri geometrici incogniti, che sono quelli da ricercare. Lo scopo del modello virtuale è di sovrapporre il suo output alle curve ricavate da prove sulla valvola reale. La stima dei parametri ignoti avviene tramite la risoluzione di un problema di ottimizzazione.

Questa operazione, seppur complessa, è necessaria in quanto i parametri stimati non sono ottenibili in maniera diretta tramite misure. Il modello virtuale diventa, quindi, un sistema indiretto di misura.

L'estrazione di dati avrà come scopo quello di monitorare l'andamento della produzione ed evidenziare trend e rischi nel processo produttivo.

# 4.1 Modello Simulink

Il cuore del lavoro risiede nell'implementazione Simulink del modello matematico della valvola. La sua flessibilità consente di osservare il comportamento della valvola in diverse condizioni operative, permettendo di simulare sia il funzionamento

normale, sia di calcolare i risultati delle prove di *flow gain* e *pressure gain*. L'implementazione traduce in ambiente di simulazione le relazioni tra pressione e portata attraverso gli orifizi che compongono la valvola, seguendo i principi matematici delineati nella sezione 3. Questo approccio trasforma i modelli teorici già sviluppati in uno strumento di simulazione pratico ed efficace. Il modello riproduce il circuito idraulico equivalente illustrato in 3.5, composto da sedici orifizi interconnessi, permettendo di validare le prestazioni delle valvole confrontando i risultati con le prove idrauliche reali. Si riporta nella figura 4.1 la configurazione idraulica della valvola rappresentata nello schema a blocchi.

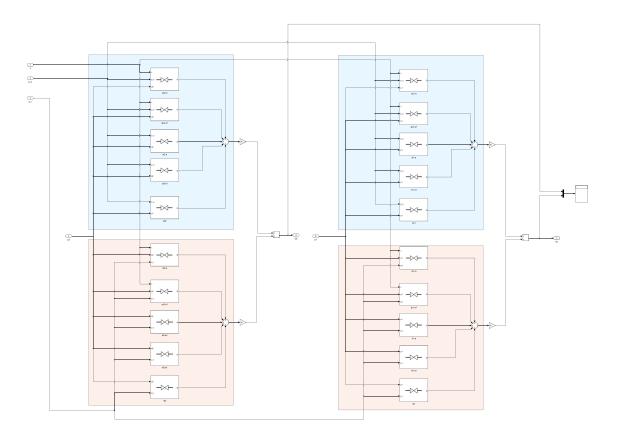


Figura 4.1: Curve di Portata

La struttura del modello permette la caratterizzazione del funzionamento nelle tre configurazioni desiderate:

- Funzionamento normale della valvola: Il modello calcola le portate nelle camere di controllo in funzione delle pressioni di alimentazione (supply), scarico (return) e delle pressioni nelle camere di controllo stesse. Attraverso l'utilizzo dei blocchi Algebraic Constraint di Simulink, è possibile determinare in modo iterativo le pressioni nelle camere di controllo note le portate, realizzando così un'analisi bidirezionale delle relazioni pressione-portata.
- Prova *flow gain*: In questa configurazione, il modello consente di impostare la pressione di *supply* alle porte di controllo e la pressione di *return* alle porte di alimentazione e scarico, producendo i diagrammi di *flow gain* come nelle prove descritte in 3.7. Tale implementazione è fondamentale per la validazione del modello attraverso il confronto con i dati sperimentali.
- Prova pressure gain: Il modello permette di simulare situazioni in cui la portata dalle camere di controllo è impostata a zero, consentendo di stimare le pressioni risultanti in queste camere, in maniera analoga alle prove reali (sezione 3.7).
   Questa analisi viene effettuata sfruttando le funzionalità di risoluzione iterativa di Simulink per determinare i punti di equilibrio del sistema.

La codifica in Simulink ha offerto numerosi vantaggi per l'implementazione pratica di questo modello. La sua interfaccia grafica facilita la rappresentazione visiva dei componenti idraulici e delle loro interconnessioni, mentre la natura modulare del software consente di modificare agevolmente le configurazioni di test per replicare le diverse condizioni operative delle prove sperimentali. Simulink ha permesso inoltre di strutturare il modello in sottosistemi gerarchici, migliorando la leggibilità e la manutenibilità del codice, aspetti fondamentali per un'analisi dettagliata e per eventuali futuri sviluppi.

Nel paragrafo successivo verranno esaminati i dettagli dell'implementazione in Simulink degli orifizi che costituiscono il circuito idraulico, illustrando come le equazioni matematiche descritte nel capitolo 3 siano state tradotte nei corrispondenti blocchi funzionali del software di simulazione.

Il modello sfrutta i dati geometrici della valvola e i dati relativi alle condizioni del fluido contenuti rispettivamente nei files ValveData e GeneralData.

## 4.1.1 Modellazione degli orifizi

La modellazione degli orifizi avviene in modo parametrico, mettendo in relazione i parametri del modello con la geometria effettiva della valvola. Per ottenere un modello fedele, sono stati inclusi tutti gli orifizi, compresi quelli presenti negli spazi tra camicia intermedia e corpo esterno. Per evitare complessità superflue, tuttavia, si è considerato solo il funzionamento in condizioni normali: il cassetto interno si muove mentre la camicia intermedia rimane in posizione neutra escludendo le situazioni di *jamming*. Nel modello di simulazione vengono quindi modellati due tipi di orifizi, quelli in cui l'area dipende dalla posizione del cassetto e quelli a sezione fissa, la cui area non varia durante la corsa.

La modellazione degli orifizi ad area variabile si articola nei seguenti step:

#### 1. Calcolo della posizione effettiva del cassetto.

Si somma un opportuno offset (definito dalla geometria della valvola) allo spostamento del cassetto, così da ottenere la posizione relativa rispetto alla luce di passaggio.

#### 2. Calcolo dell'area istantanea

Si utilizza l'algoritmo descritto nel paragrafo 3.4.2 per determinare l'area istantanea dell'orifizio in funzione della posizione del cassetto.

#### 3. Correzione dell'area

All'area così calcolata si applica una riduzione secondo la formula

$$A^* = \frac{1}{\sqrt{\frac{1}{A} + \frac{2}{A_C} + \frac{2}{A_S}}}.$$

$$43$$

In questo modo si tiene conto dell'area delle porte di controllo  $(A_C)$  e di supply  $(A_S)$ . Tale passaggio fornisce un modello più realistico senza dover gestire ogni singola perdita di carico separatamente. Infatti:

- Effetto delle perdite di carico: ogni flusso che attraversa una sezione produce una caduta di pressione; ridurre l'area totale simula la combinazione di queste perdite.
- Leaking Flow (Perdite interne): per piccoli spostamenti del cassetto rispetto allo zero idraulico, possono verificarsi perdite attraverso sezioni molto ridotte (porte di controllo), non significative rispetto al flusso principale ma comunque presenti.
- Semplificazione di calcolo: gestendo una sola area effettiva, si evita di modellare ogni singolo passaggio, ottenendo comunque una stima affidabile del comportamento globale.

#### 4. Calcolo del coefficiente di efflusso

Il coefficiente di efflusso si ottiene dalla relazione

$$c_d = c' \cdot c_{ds} \tag{4.2}$$

dove

$$c_{ds} = A \left[ \ln(Re+1)^B \right]^C. \tag{4.3}$$

Si tratta di una formula empirica [22], i cui parametri A, B, e C vengono determinati minimizzando la differenza tra la risposta simulata e il comportamento reale della valvola (in modo analogo a quanto si vedrà nella Sezione 4.4.4 per la stima dei parametri critici di ricoprimento e zero idraulico).

Il termine

$$c' = 1 + \left(\frac{1}{c_{ds} - 1}\right) \tanh\left[k\left(\frac{r_c}{d_h}\right)\right] \tag{4.4}$$

funge da fattore correttivo per tenere conto dei raggi di raccordo  $r_c$  delle luci di passaggio; k è un parametro empirico.

Anche l'effetto dell'overlap tra cassetto e camicia intermedia influisce sul coefficiente di efflusso del flusso, figura 4.2. Per tenere conto dell'influenza dell'effetto di ingresso, è possibile definire un coefficiente di efflusso efficace  $c_{de}$ 

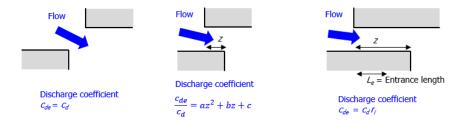


Figura 4.2: Effetto della lunghezza d'ingresso sul coefficiente di efflusso

Se non c'è overlap tra cassetto e camicia (z < 0), non ci sono effetti sul coefficiente di efflusso,  $c_{de} = c_d$ . Se invece il ricoprimento è positivo z > 0, vale:

$$\frac{c_{de}}{c_d} = az^2 + bz + c \tag{4.5}$$

dove:

- z rappresenta l'overlap tra cassetto e camicia;
- $a, b \in c$  sono coefficienti definiti come:

$$-a = \left(\frac{1-r_i}{Ad_h^2 + 4L_e d_h + L_e^2}\right),$$
  

$$-b = -2aL_e,$$
  

$$-c = r_i + aL_e^2.$$

Il parametro  $r_i$  rappresenta il rapporto tra il coefficiente di efflusso a piena lunghezza di sviluppo e quello per ricoprimento inferiore, ed è un valore empirico. La lunghezza di sviluppo completo è definita come:

$$L_e = 0.25 Red_h. \tag{4.6}$$

Quando il valore del ricoprimento supera quello della lunghezza di completo sviluppo  $L_e$ , il coefficiente non può aumentare ulteriormente e raggiunge il valore massimo, pari a  $c_{de} = r_i c_d$ 

## 5. Calcolo della portata.

Infine, si determinano la portata principale, mediante la classica equazione di efflusso (equazione 3.3), e le eventuali perdite secondarie nella sezione anulare (formula di Hagen-Poiseuille, equazione 3.7).

Per gli orifizi di area fissa, la procedura di calcolo è analoga, ma l'area non varia con la posizione del cassetto, rimanendo costante durante l'intera corsa.

La figura 4.3 mostra lo schema a blocchi utilizzato per la modellazione di un orifizio ad area variabile e sintetizza gli step descritti.

## 4.2 Simulazione del test Flow Gain

Sviluppato il modello, è possibile simulare il comportamento della valvola. Poiché Simulink sviluppa le sue simulazioni nel dominio temporale, è possibile definire un segnale rampa per imporre la posizione istantanea del cassetto, secondo la legge:

$$x = slope * time + max_{retraction}$$
 (4.7)

la pendenza della rampa è calcolata come:

$$slope = \frac{max_{extension} - max_{retraction}}{simulation \ time} \tag{4.8}$$

ovvero il rapporto tra la corsa del cassetto e il tempo di simulazione. In un file di inizializzazione è possibile richiamare tutti i parametri richiesti dal modello e avviare una simulazione. Se la configurazione del modello corrisponde a quella di figura 4.4, si ottiene la simulazione di una prova di Flow Gain. Se si effettuano delle

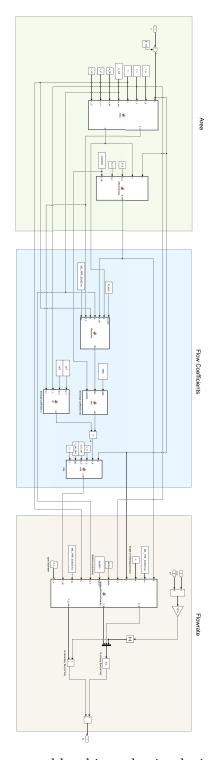


Figura 4.3: Schema a blocchi per la simulazione di un orifizio

simulazioni della prova, i risultati (figura 4.5) rispecchiano quelli attesi, con curve simili a quelle delle prove reali.

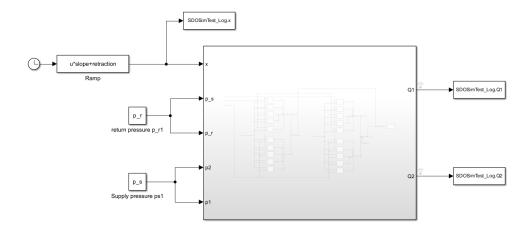


Figura 4.4: Configurazione test Flow Gain del modello di simulazione

# 4.3 Validazione del modello

Per valutare l'efficacia del modello sviluppato, le curve di output sono state confrontate con due modelli analoghi implementati in Excel. L'analisi mira a verificare l'accuratezza delle previsioni fornite dal modello proposto, evidenziando eventuali differenze e vantaggi rispetto alle soluzioni esistenti.

## 4.3.1 Modello Pressure Gain

Il primo confronto è stato effettuato con un modello preesistente, già validato tramite prove sperimentali, che simula il comportamento della valvola durante il test di *Pressure Gain*.

Nel modello Simulink, le porte di alimentazione e scarico sono soggette alle rispettive pressioni di esercizio, mentre le porte di controllo vengono tappate. Per simulare una porta tappata, è necessario imporre una portata nulla, impostando

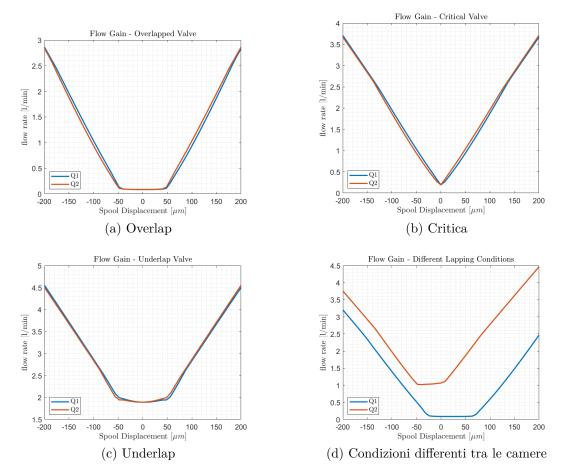


Figura 4.5: Confronto tra varie simulazioni della prova Flow Gain

di conseguenza la pressione corretta alle porte. Questa condizione è implementata utilizzando il blocco Simulink Algebraic Constraint, che consente di vincolare la pressione d'ingresso affinché la portata risultante sia nulla:

$$P_i: Q_i(P_i) = 0 (4.9)$$

La configurazione adottata è illustrata in figura 4.6 e permette di replicare fedelmente le condizioni di test sperimentali.

Per il calcolo della portata di leakage, si considerano le perdite idrauliche attraverso la valvola, che avvengono lungo due percorsi distinti: il primo dalla porta di

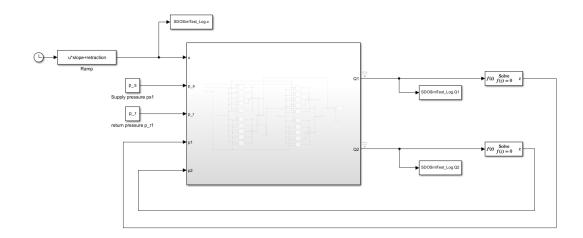


Figura 4.6: Configurazione test *Pressure Gain* del modello di simulazione

alimentazione alla porta di controllo 1, il secondo dalla porta di controllo 2 alla porta di scarico. La portata totale di leakage è quindi ottenuta sommando i contributi di questi due percorsi, fornendo una misura complessiva delle perdite idrauliche che si verificano all'interno della valvola.

Il confronto tra i due modelli è stato eseguito su una stessa configurazione di prova. I risultati del confronto, riportati in figura 4.7, mostrano una buona corrispondenza tra i modelli, evidenziando l'affidabilità della simulazione sviluppata. I dati relativi all'errore sono riassunti in tabella 4.1, da cui emerge un errore relativo ridotto, a conferma della validità del modello proposto. Per evidenziare la somiglianza tra le curve è stato riportato il coefficiente di correlazione di Pearson, che misura il grado di relazione tra due curve:

$$r = \frac{\sum_{i=1}^{n} (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^{n} (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^{n} (y_i - \bar{y})^2}}$$
(4.10)

dove  $x_i$  e  $y_i$  sono i valori delle due variabili,  $\bar{x}$  e  $\bar{y}$  le rispettive medie, e n il numero di campioni.

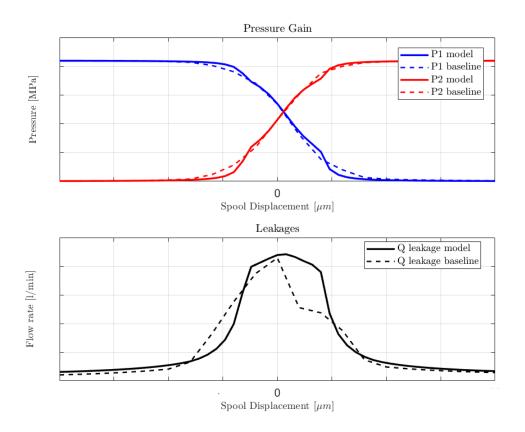


Figura 4.7: Confronto con modello pre esistente - Pressure Gain

Curva	MAE (%)	RMSE	Correlazione di Pearson
P1	23.52	0.5459	0.9989
P2	12.75	0.5589	0.9986
Q leakage	9.49	0.0410	0.9605

Tabella 4.1: Comparazione con modello pre esistente - Pressure Gain

## 4.3.2 Modello Flow Gain

Il secondo confronto è stato effettuato con un modello che simula una prova di Flow Gain differente da quella descritta in 3.7. In questo caso, il test viene eseguito alimentando le porte di supply e return, mentre le camere di controllo 1 e 2 sono collegate tra loro.

La simulazione di questa condizione è realizzata imponendo un vincolo sulla differenza tra la portata entrante e quella uscente dalla valvola, utilizzando il blocco Simulink Algebraic Constraint, figura 4.8. In particolare, poiché le porte di controllo sono connesse, la differenza in valore assoluto delle portate che le attraversano deve essere nulla.

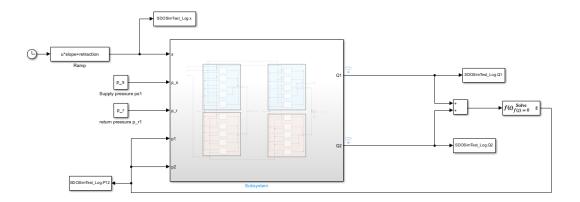


Figura 4.8: Configurazione test Flow Gain del modello di simulazione

Anche in questo caso, il confronto tra i due modelli è stato eseguito sulla stessa configurazione della valvola. I risultati della simulazione, riportati in figura 4.9, mostrano il comportamento dei modelli a confronto. I dati relativi all'errore sono riassunti in tabella 4.2.

Curva	MAE (%)	RMSE	Correlazione di Pearson
Q	6.95	0.0246	0.9993

Tabella 4.2: Comparazione con modello preesistente - Flow Gain

Il confronto con i modelli pre esistenti ha evidenziato prestazioni soddisfacenti, confermando l'affidabilità e la solidità del modello sviluppato. Oltre a garantire una buona accuratezza nella simulazione del comportamento della valvola, il principale valore aggiunto di questo approccio risiede nella sua maggiore flessibilità e capacità di integrazione in sistemi più complessi. In particolare, il modello può essere

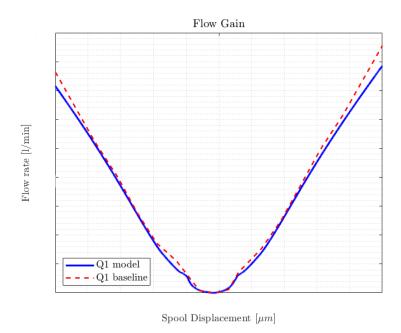


Figura 4.9: Confronto con modello pre esistente - Pressure Gain

facilmente incorporato in simulazioni più articolate, come quelle di servoattuatori completi, consentendo un'analisi realistica e dettagliata delle dinamiche del sistema.

Un ulteriore vantaggio è la possibilità di sfruttare il modello per analisi avanzate dei dati, facilitando la stima di parametri critici che non sarebbero direttamente misurabili nei test sperimentali. Questo aspetto apre la strada a metodologie più sofisticate per il monitoraggio delle prestazioni e l'ottimizzazione del design.

# 4.4 Stima dei parametri incogniti

Come anticipato l'obbiettivo del modello è stimare alcuni parametri incogniti relativi alle valvole a partire da prove sperimentali di *Flow Gain*.

# 4.4.1 Elaborazione dei dati grezzi

Il primo passo dell'analisi dei dati consiste nell'elaborazione dei dati grezzi acquisiti dai banchi di prova. Durante la fase di test della portata, i dati vengono registrati

automaticamente e salvati in file testuali. In ciascun file, le informazioni sono organizzate in due colonne, in cui a ogni posizione dello *spool* corrisponde il valore di portata misurato dal flussimetro. Per ogni valvola vengono generati due file distinti, corrispondenti alle due camere di controllo, con i dati acquisiti da due flussimetri separati, come descritto nel Capitolo 3. Una volta raccolti i dati relativi alle diverse valvole, questi vengono convertiti in file '.mat' per agevolarne l'elaborazione in MATLAB.

La prima fase del trattamento dei dati prevede la loro pulizia, necessaria per garantire una correlazione univoca e priva di anomalie. L'analisi grafica dei dati (Figura 1) evidenzia la presenza di artefatti generati dalla procedura di acquisizione. Per correggere tali imperfezioni, si procede innanzitutto con l'eliminazione dei duplicati nel vettore delle posizioni, sostituendo i valori di portata associati con la loro media. Successivamente, il vettore delle posizioni viene ordinato in ordine crescente, riassegnando coerentemente i valori di portata per preservare l'integrità del dataset. Infine, per ridurre il rumore ad alta frequenza, è possibile applicare un filtro passa-basso, migliorando così l'affidabilità dei dati elaborati.

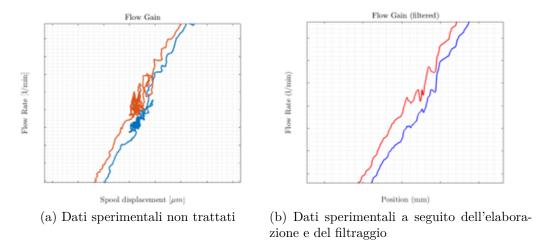


Figura 4.10: Plot dei dati sperimentali prima e dopo l'elaborazione preliminare

## 4.4.2 Estrazione preliminare dei parametri

Per ottenere dei dati di partenza da fornire al modello di simulazione della *Main Control Valve*, è stato sviluppato un algoritmo in MATLAB che consente di stimare approssimativamente i ricoprimenti a partire dalle curve di test di portata. Le curve, ottenute durante i test idraulici, presentano una forma caratteristica a 'V', con un tratto approssimativamente orizzontale in prossimità dello zero idraulico nei casi in cui è presente overlap o underlap. Questa caratteristica delle curve è stata sfruttata per definire un metodo di stima dei ricoprimenti, che si basa sull'estensione dei rami della curva fino a intersecare la linea di portata nulla. Le intersezioni ottenute su questa linea permettono di calcolare la distanza tra i due punti, che corrisponde approssimativamente al valore del ricoprimento.

Facendo riferimento a una curva d'esempio, come quella mostrata in figura 4.11, il primo passo consiste nel filtrare i dati per rimuovere eventuali punti anomali che superano una soglia di portata predefinita. Successivamente, viene individuato il minimo della curva di portata, che funge da riferimento per la suddivisione nei due rami:

- Il ramo discendente, composto dai dati fino al minimo;
- Il ramo ascendente, costituito dai dati successivi al minimo.

Per ciascun ramo viene applicata la funzione interp\_branch, progettata per elaborare separatamente i rami della curva e restituire i coefficienti della retta interpolante. Questa retta rappresenta il comportamento lineare del flusso idraulico, escludendo la porzione di dati in prossimità del minimo, dove la pendenza della curva cambia drasticamente.

La funzione interp\_branch segue una logica specifica per garantire un'approssimazione robusta:

• Se il ramo in esame ha portata decrescente, i vettori di posizione e portata vengono ribaltati per uniformare l'elaborazione;

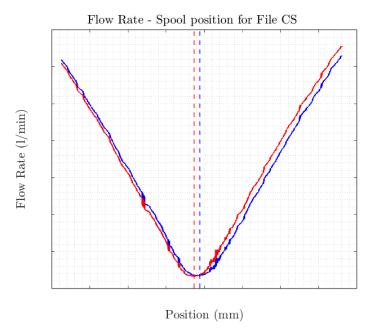
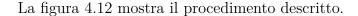


Figura 4.11: Curve di Portata

- La posizione del cassetto viene suddivisa uniformemente in 1000 punti e l'array della portata viene interpolato di conseguenza per garantire una risoluzione uniforme;
- Il ramo è suddiviso in un numero prefissato di sezioni, per ciascuna delle quali viene tracciata una retta interpolante;
- Il processo continua fino a quando la variazione del coefficiente angolare tra sezioni consecutive non supera una soglia prestabilita. In caso contrario, la sezione viene esclusa e il ciclo si interrompe;
- Una volta identificate le sezioni utili, si calcola una media pesata dei coefficienti ottenuti, assegnando pesi esponenziali per dare maggiore importanza alle sezioni più vicine al minimo di portata.

Le rette interpolanti ottenute per ciascun ramo vengono quindi utilizzate per determinare i punti di intersezione con la linea di portata nulla (y=0). La distanza tra queste due intersezioni fornisce il valore del ricoprimento, indicato come covering.

Infine, viene calcolato anche il punto di intersezione tra le due rette interpolanti, identificato come x\_cross, che rappresenta lo zero idraulico della valvola. Questi due parametri estratti costituiscono gli elementi fondamentali per la successiva fase di simulazione del modello della valvola.



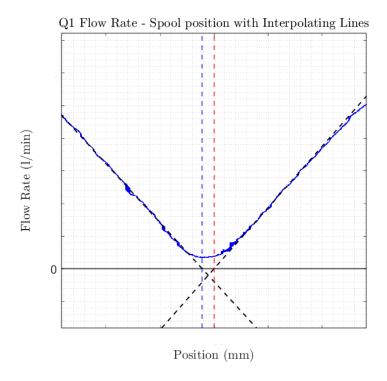


Figura 4.12: Stima dei parametri dalla geometria delle curve di portata

## 4.4.3 Identificazione della valvola

È possibile che i dati di prova di portata non si riferiscano a una MCV di un attuatore del rotore principale, ma piuttosto a quella di un rotore di coda. Per distinguere tra i due tipi di valvola, è possibile condurre un'analisi dei dati. Le valvole di un *Tail Rotor Actuator*, infatti, sono progettate per gestire portate più elevate e dispongono di luci di passaggio di dimensioni maggiori.

Durante una prova di portata, a parità di spostamento del cassetto, si osserva una variazione più significativa della portata rispetto a una MCV di un MRA. Per effettuare questa distinzione, si utilizza l'algoritmo descritto in precedenza per generare una retta che interpoli uno dei rami della curva di portata. Se il coefficiente angolare della retta supera una determinata soglia, è possibile identificare con sicurezza la valvola come appartenente a un TRA.

## 4.4.4 Problema di ottimizzazione

L'obiettivo del modello è stimare i parametri che consentono di sovrapporre l'output simulato ai dati sperimentali delle prove di portata, al fine di determinare con precisione i valori incogniti. Per identificare tali parametri, si affronta un problema di ottimizzazione che mira a minimizzare la discrepanza tra le curve simulate e i dati sperimentali.

A tal fine, è stato impiegato il tool *Parameter Estimator* di Simulink (figura 4.13), che offre un'interfaccia grafica intuitiva per configurare gli esperimenti, selezionare i dati di confronto e definire i parametri da stimare. Lo strumento consente di specificare valori iniziali per i parametri e scegliere l'algoritmo di ottimizzazione più adatto. Inoltre, si presta a un'analisi efficiente di numerose simulazioni, grazie alla possibilità di automatizzare il processo di stima tramite la generazione di una funzione MATLAB.

La funzione generata è stata opportunamente modificata per accettare come input i vettori dei grafici desiderati e un array di celle contenente i nomi dei parametri da stimare.

Il processo di ottimizzazione numerica si basa su metodi numerici non lineari, come l'algoritmo *Trust-Region Reflective*, implementato nel programma tramite la funzione MATLAB lsqnonlin. La funzione risolve il seguente problema:

$$\min_{\mathbf{x}} \sum_{i=1}^{n} r_i(\mathbf{x})^2 \tag{4.11}$$

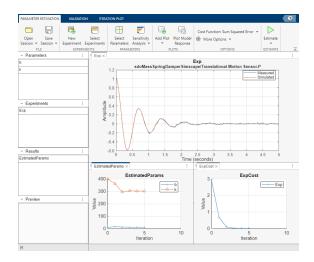


Figura 4.13: Tool Parameter Estimator di Simulink

dove:

- 1.  $\mathbf{x}$  è il vettore dei parametri da stimare
- 2.  $r_i(\mathbf{x})$  rappresenta il residuo tra i dati simulati e quelli sperimentali

L'algoritmo definisce una regione di fiducia attorno alla soluzione corrente, all'interno della quale costruisce un modello semplificato della funzione obiettivo. A ogni iterazione, i parametri vengono aggiornati con un passo limitato a questa regione. Se il nuovo punto riduce efficacemente l'errore, la regione di fiducia viene ampliata; altrimenti, viene ridotta per migliorare la stabilità del processo.

# 4.5 Performance del modello

Questo approccio si è dimostrato efficace nel ridurre la discrepanza tra i dati simulati e quelli sperimentali, permettendo una stima accurata dei parametri chiave del modello. L'applicazione dell'algoritmo di ottimizzazione alla minimizzazione della differenza tra le curve idrauliche reali e simulate ha prodotto una sovrapposizione accurata tra le due serie di dati, come mostrato in figura 4.14.

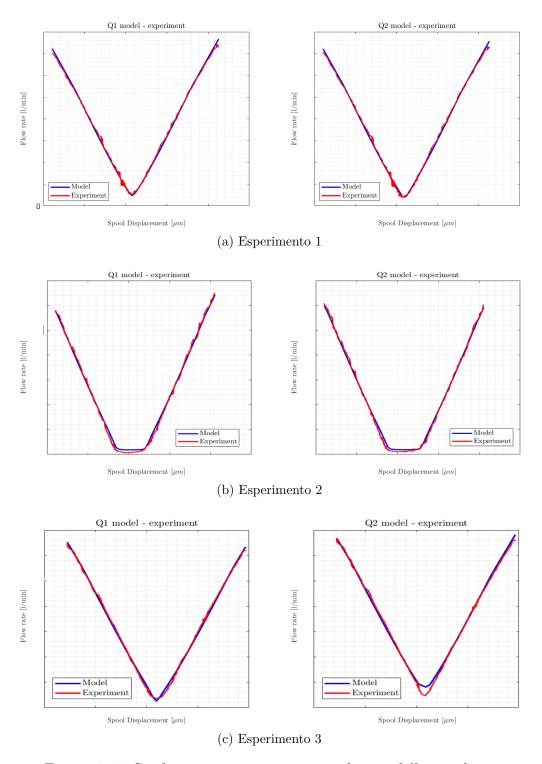


Figura 4.14: Confronto tra prove sperimentali e modello simulato.

Per quantificare l'accuratezza della simulazione, la tabella 4.3 riporta i valori di MAE (%), RMSE e coefficiente di correlazione di Pearson per ciascun esperimento. I risultati ottenuti evidenziano la robustezza del metodo nel riprodurre le caratteristiche del sistema reale.

Esperimento	Q	MAE (%)	RMSE	Correlazione di Pearson
1	Q1	3.82	0.0385	0.9996
	Q2	5.12	0.0402	0.9994
2	Q1	15.37	0.0534	0.9994
	Q2	8.92	0.0530	0.9992
3	Q1	5.26	0.0402	0.9991
3	Q2	7.00	0.0573	0.9985

Tabella 4.3: Metriche di valutazione del modello per i diversi esperimenti.

I parametri che vengono variati per ottenere la sovrapposizione ottimale tra modello e dati sperimentali includono gli zeri idraulici, i ricoprimenti e i raggi di raccordo del cassetto della valvola. L'analisi dell'evoluzione di questi parametri nel tempo, ottenuta applicando l'algoritmo al dataset disponibile, è illustrata in figura 4.15.

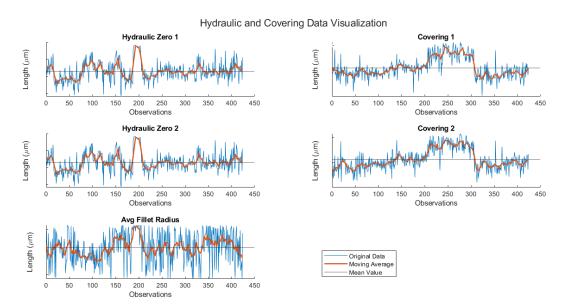


Figura 4.15: Evoluzione dei parametri di ottimizzazione nel tempo.

## Capitolo 5

# Machine Learning

## 5.1 Introduzione al Machine Learning

In questo capitolo si vuole introdurre il Machine Learning e mostrare come questa tecnologia possa essere applicata per effettuare analisi su dati industriali. Nel contesto dello *smart manufacturing*, l'importanza dell'analisi avanzata dei dati è un obiettivo sempre più rilevante. Infatti, le industrie moderne, tra le quali quella aerospaziale, sono caratterizzate da una crescente complessità dei processi produttivi e da una mole elevata di dati generati da sensori, macchinari e sistemi di monitoraggio. Questi dati, se analizzati in modo efficace, possono fornire informazioni preziose per ottimizzare le operazioni, ridurre i costi e migliorare la qualità dei prodotti, [9]. Se questi dati vengono raccolti in database ben strutturati e organizzati, è possibile estrarre una grande quantità di informazioni significative. L'analisi di questi big data consente di identificare pattern, fare previsioni e ottimizzare i processi produttivi. Il machine learning, o apprendimento automatico, è una delle soluzioni che si possono utilizzare per sfruttare questo potenziale. Il machine learning si distanzia dai metodi di analisi e previsione classici in quanto non viene fornita una funzione esplicita che lega input ad output, ma si basa su modelli matematici capaci di apprendere direttamente dai dati. Questo approccio si rivela particolarmente efficace

in scenari caratterizzati da elevata variabilità e complessità, dove le relazioni tra le variabili possono essere non lineari o difficili da modellare manualmente, [3]. Inoltre, la capacità del machine learning di adattarsi ai dati disponibili e di migliorare le proprie prestazioni nel tempo è un elemento chiave per affrontare sfide sempre più complesse. Questa tecnologia basata sui dati si allinea perfettamente con i principi dell'Industria 4.0, dove la flessibilità e l'ottimizzazione continua sono essenziali per mantenere la competitività.

## 5.2 Paradigmi di apprendimento

L'apprendimento automatico include diversi metodi che permettono agli algoritmi di derivare le relazioni tra i dati. I paradigmi di apprendimento sono classificati in categorie basate sul tipo di feedback che il sistema di apprendimento usa, [20].

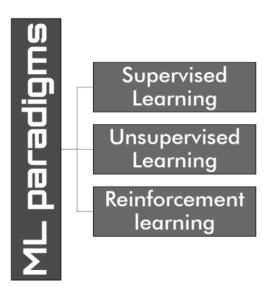


Figura 5.1: Paradigmi dell'apprendimento automatico

#### 5.2.1 Supervised Learning

L'apprendimento supervisionato è una tecnica di machine learning che permette al calcolatore di risolvere problemi in maniera automatica attraverso l'addestramento su un set di dati etichettati. Un set di dati etichettati è composto da dati di input, tipicamente rappresentati come array di elementi detti predictors, e un set di output associati (response variables) che funge da riferimento per il modello. Durante l'addestramento, l'algoritmo apprende una funzione che associa gli input agli output, ottimizzando iterativamente i suoi parametri per minimizzare l'errore tra le predizioni e i risultati attesi. Una volta completata la fase di apprendimento, il modello può generalizzare su nuovi dati non visti, fornendo previsioni accurate. Il supervised learning si occupa di risolvere due tipi di problemi, in base al risultato che si vuole ottenere. Il primo è quello della classificazione che si occupa di assegnare ai dati in ingresso delle categorie specifiche. Questo approccio trova applicazione in numerosi ambiti. Ad esempio, nel riconoscimento di immagini, può essere utilizzato per catalogare gli oggetti. In medicina, potrebbe supportare diagnosi classificando pazienti come a rischio o non, sulla base di parametri biologici. Nell'ambito industriale, invece, potrebbe permettere di identificare la tipologia di guasto in un macchinario, migliorando l'efficienza della manutenzione. L'altra variante dell'apprendimento supervisionato è la regressione. Essa si concentra sulla stima di un valore numerico continuo. A differenza della classificazione, non mira a categorizzare i dati ma a prevedere grandezze misurabili. Anche la regressione offre una vasta gamma di applicazioni pratiche. Nel settore immobiliare, ad esempio, può essere utilizzata per stimare il valore di una casa tenendo conto di variabili come la posizione, la superficie e le caratteristiche strutturali. In ambito finanziario, trova impiego nella previsione del valore futuro di un titolo o nella valutazione del rischio legato a un investimento. Nel campo dell'energia, la regressione è utile per calcolare il consumo elettrico di un impianto in funzione dei dati operativi, consentendo una migliore pianificazione e gestione delle risorse.

#### 5.2.2 Unsupervised Learning

L'obiettivo dell'apprendimento non supervisionato è estrarre informazioni da database senza una conoscenza preliminare del contenuto da analizzare. A differenza dell'apprendimento supervisionato, non ci sono informazioni sulle classi di appartenenza o sugli output. L'obbiettivo dell'unsupervised learning è quindi quello di ottenere un modello capace di scoprire proprietà interessanti sui dati in ingresso, come raggruppamenti, detti clusters, di esempi con simili caratteristiche. Una applicazione può essere quella dei motori di ricerca che generano una lista di link correlati alle parole chiave inserite. Un'altra applicazione dell'unsupervised learning è quella della dimensionality reduction, ovvero la riduzione della dimensionalità dei dati. Questo processo consente di trasformare un insieme di dati ad alta dimensionalità in uno spazio a dimensioni inferiori, preservando il più possibile le informazioni rilevanti. La riduzione della dimensionalità è particolarmente utile per la visualizzazione dei dati, l'eliminazione di rumore e la semplificazione dei modelli di machine learning, riducendo così il rischio di overfitting<sup>1</sup>. Un'altra applicazione importante dell'apprendimento non supervisionato è l'anomaly detection, ovvero l'individuazione di anomalie nei dati. Questo approccio viene utilizzato in contesti quali la sicurezza informatica, per rilevare comportamenti sospetti, o nel monitoraggio di sistemi industriali, per individuare guasti o malfunzionamenti.

### 5.2.3 Reinforcement Learning

Il Reinforcement learning, o apprendimento per rinforzo, è uno dei paradigmi del machine learning e mira a sviluppare algoritmi in grado di apprendere e adattarsi ai cambiamenti dell'ambiente. In questo tipo di algoritmi, i segnali esterni, detti di rinforzo, vengono ricevuti in base alle scelte effettuate dall'algoritmo. Se la scelta è

<sup>&</sup>lt;sup>1</sup>L'overfitting si verifica quando un modello si adatta troppo fedelmente ai dati di addestramento, risultando non adatto ad effettuare previsioni accurate su nuovi dati

corretta, essa genera una ricompensa, mentre se errata, porta a una penalità. L'obiettivo finale è quello di massimizzare il risultato atteso senza fornire una guida su come aggiornare il sistema. A differenza dell'apprendimento supervisionato, dove i dati di addestramento forniscono le risposte corrette, nel reinforcement learning l'agente deve imparare autonomamente dalle esperienze, interpretando i feedback ricevuti come rinforzi piuttosto che nuovi input. Questa capacità di apprendimento risulta particolarmente utile in contesti complessi, dove è difficile definire regole esplicite. L'approccio comprende sia l'apprendimento passivo, in cui apprende l'utilità di determinate azioni e modella l'ambiente, sia l'apprendimento attivo, in cui l'agente seleziona le migliori strategie comportamentali durante l'esplorazione dell'ambiente. Le applicazioni del reinforcement learning sono molteplici, spaziano dal controllo dei veicoli autonomi alla gestione delle catene di approvvigionamento o ottimizzazione energetica.

## 5.3 Applicazioni al caso studio

In questa sezione verranno illustrate le applicazioni sviluppate per analizzare i dati sperimentali delle prove idrauliche delle MCV utilizzando algoritmi di apprendimento automatico. L'obiettivo è dimostrare concretamente come le tecniche di machine learning possano essere impiegate per estrarre informazioni significative dai dati raccolti, individuando tendenze, anomalie e correlazioni non immediatamente evidenti con metodi tradizionali. L'analisi automatizzata consente di effettuare valutazioni senza basarsi su modelli deterministici, offrendo strumenti flessibili e adattabili a fenomeni complessi. Le metodologie analizzate comprendono tre principali approcci: l'apprendimento non supervisionato per l'anomaly detection, utilizzato per identificare deviazioni rispetto ai comportamenti attesi; la regressione supervisionata, impiegata per la previsione di parametri di interesse a partire dai dati disponibili; e modelli di deep learning applicati all'analisi di serie temporali, utili per catturare

relazioni non lineari e tendenze nei dati acquisiti nel tempo. L'integrazione di queste tecniche permette non solo di migliorare l'interpretazione dei risultati sperimentali, ma anche di supportare il processo decisionale legato alla produzione.

#### 5.3.1 Anomaly detection tramite unsupervised learning

La prima applicazione pratica che si intende analizzare riguarda la ricerca di anomalie all'interno del dataset. Partendo dall'insieme delle prove idrauliche disponibili, è possibile utilizzare algoritmi di apprendimento non supervisionato per identificare rapidamente eventuali valvole che si discostano dagli standard produttivi, [24]. Questo approccio presenta diversi vantaggi significativi:

- In primo luogo, consente l'analisi completa dell'intero dataset, anche in presenza di grandi quantità di dati, in tempi ridotti. Ciò permette di isolare i casi anomali per uno studio approfondito, facilitando l'individuazione di pattern ripetitivi che potrebbero indicare le cause sistematiche alla base delle divergenze produttive.
- Un ulteriore vantaggio risiede nella possibilità di sviluppare un modello di anomaly detection, già addestrato e pronto per l'analisi di nuovi casi. Questo modello può essere integrato nel processo produttivo, consentendo un monitoraggio continuo e l'individuazione tempestiva di eventuali deviazioni dallo standard.

Esistono diversi algoritmi adatti allo scopo, uno di questi è l'*Isolation Forest*. Questa tecnica di rilevamento dei casi anomali è basata su alberi binari di isolamento ed è progettata per identificare in modo efficiente i punti atipici in grandi dataset. A differenza di altri metodi che si basano sulla densità dei dati o sulla distanza tra i punti, l'algoritmo sfrutta l'idea che le anomalie siano osservazioni isolate, che si differenziano significativamente dal resto dei dati.

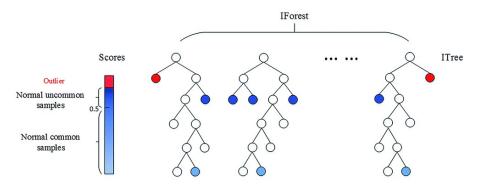


Figura 5.2: Algoritmo Isolation Forest

L'algoritmo costruisce una foresta di isolation trees utilizzati per suddividere i dati in sottoinsiemi più piccoli. Un isolation tree è un albero binario in cui ogni nodo rappresenta una suddivisione dei dati. La divisione avviene scegliendo casualmente una caratteristica dei dati e poi selezionando un valore casuale all'interno del range di quella caratteristica. Questo processo di suddivisione continua fino a quando i dati non sono separati in foglie, ovvero in punti o piccoli gruppi di punti. Poiché le anomalie tendono a essere diverse dalla maggior parte dei dati, esse vengono isolate rapidamente, richiedendo un numero inferiore di suddivisioni (una profondità dell'albero più bassa) rispetto ai punti normali (figura 5.2). In altre parole, un punto che è isolato in pochi passaggi è probabilmente un'anomalia, mentre un punto che richiede molte suddivisioni per essere isolato è considerato normale. Infatti, la grandezza che viene utilizzata per calcolare l'anomaly score è proprio la lunghezza del percorso, ovvero il numero di passaggi necessari per isolare un punto di un albero. L'algoritmo calcola la media della lunghezza del percorso su ogni albero della foresta per ottenere una misura finale di anomalia per ciascun punto. Il punteggio di anomalia è calcolato come segue:

$$s(x) = 2^{-\frac{E[h(x)]}{c(n)}} \tag{5.1}$$

dove:

1. E[h(x)] è la lunghezza media del percorso lungo tutti gli isolation trees

2. c(n) è la lunghezza media del percorso di ricerche senza successo in un albero binario di n osservazioni.

Il valore è prossimo a 1 quando E[h(x)] è vicino allo zero, mentre è prossimo a 0 quando  $E[h(x)] \approx n - 1$ . Un punteggio compreso tra 0 e 0.5 normalmente indica un'osservazione normale.

La natura binaria degli alberi (ogni nodo interno divide i dati in due) e la casualità nella scelta degli *split* rendono il metodo efficiente e adatto a dataset di grandi dimensioni, riducendo il rischio di *overfitting* e sfruttando la diversità degli alberi per una stima robusta.

Per applicare l'algoritmo ai grafici delle prove di portata, è necessario eseguire alcune operazioni preliminari<sup>2</sup> per garantire che i dati siano omogenei e pronti per l'addestramento del modello. Uno dei principali problemi riscontrati è la variabilità nei range di spostamento del cassetto tra le diverse prove. Per affrontare questa difficoltà, è stata adottata una strategia di uniformazione del dominio, che prevede l'utilizzo della funzione cleanData.

La funzione cleanData ha il compito di interpolare i dati delle curve su un dominio comune di 100 punti, definito tra -300 e +300 micron. Tale intervallo è stato scelto in quanto consente di catturare le caratteristiche significative della maggior parte delle curve. Durante il processo, vengono rimossi i duplicati presenti nei dati originali e i valori di portata che eccedono una soglia prefissata vengono esclusi, al fine di ridurre l'influenza di valori anomali. Successivamente, i dati vengono interpolati sulle posizioni comuni mediante un'interpolazione lineare, in modo da rendere i dataset delle curve coerenti in termini di dominio.

Poiché tutti i punti associati al dominio interpolato devono essere utilizzati come predittori, è fondamentale che le curve non contengano valori nulli (NaN). Per risolvere questa criticità, è stata programmata la funzione fillNaN, la quale si

 $<sup>^2</sup>$  Il processo di preparazione dei dati per effettuare una modellazione Machine Learning è detto  $\it Feature\ Engineering$ 

occupa di completare i dati mancanti nei tratti iniziali e finali delle curve, mediante interpolazione dei valori mancanti.

La funzione fillNaN verifica la presenza di valori NaN nei punti iniziali o finali del vettore interpolato. Se sono disponibili almeno dieci valori validi nelle vicinanze, calcola una retta di regressione utilizzando il metodo dei minimi quadrati (funzione polyfit) sui punti validi circostanti. Tale retta viene utilizzata per stimare i valori mancanti nei tratti iniziali e finali, garantendo che la curva sia completa e priva di interruzioni. In caso di dati insufficienti per eseguire un fit affidabile, la funzione emette un avviso, lasciando inalterati i valori NaN.

Completate queste operazioni preliminari, vengono generate due matrici  $Q1\_clean$  e  $Q2\_clean$ , contenenti i dati relativi alle prove di portata su dominio comune. Questi dati vengono utilizzati per eseguire due tipi di rilevamento delle anomalie: il primo si concentra esclusivamente sulle curve, al fine di individuare eventuali casi isolati (ad esempio, se la produzione standard è composta da valvole underlap o critiche, una valvola overlap sarà considerata anomala). Il secondo mira a individuare le differenze tra le camere. In una valvola ideale, il comportamento nelle due camere è identico, per cui la differenza tra i grafici di portata in ciascuna camera risulta in un grafico caratterizzato da una linea piatta (Q1 - Q2 = 0 per ogni punto). Fornendo all'algoritmo i vettori delle differenze delle curve di portata, è possibile identificare i casi in cui tale differenza genera risposte diverse da quelle attese.

#### Analisi sui grafici di portata

Prima di eseguire l'analisi, le prove idrauliche vengono unite in un'unica matrice. Successivamente, si utilizza la funzione iforest per applicare l'algoritmo Isolation Forest, descritto in precedenza. Viene specificato anche un fattore di contaminazione, ovvero la percentuale ipotizzata di osservazioni anomale nel dataset.

La funzione restituisce tre output, descritti nella tabella 5.1.

Variabile	Descrizione		
forest	Modello addestrato sui dati mediante l'algoritmo. È configu		
	rabile attraverso parametri chiave come il numero di alberi		
	(NumLearners, 100 di default) e il fattore di contaminazione		
	(ContaminationFraction, che specifica la percentuale stima-		
	ta di anomalie).		
tf_forest	Vettore logico che classifica ciascuna osservazione: 0 indica		
	dati normali, mentre 1 segnala anomalie. Questa classifica-		
	zione si basa sul confronto tra il punteggio di ciascun dato		
	(s_forest) e una soglia (ScoreThreshold).		
s_forest	Vettore di anomaly scores che misura il grado di isolamento		
	di ciascun punto. Valori più alti indicano dati più isolati.		

Tabella 5.1: Output Isolation Forest

A seguito dell'addestramento del modello si possono analizzare i dati in output. È stato generato un istogramma (figura 5.3) che mostra il numero di occorrenze per i diversi valori del punteggio di anomalia. Si osserva che la maggior parte dei campioni ha, come atteso, un punteggio di anomalia basso e che la distribuzione non presenta notevoli differenze tra le osservazioni relative alle porte di controllo 1 e 2.

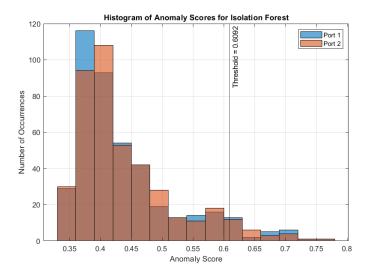


Figura 5.3: Istogramma delle occorrenze per anomaly score

Per visualizzare le forme delle curve di portata in funzione del punteggio di anomalia, è stato creato un grafico tridimensionale in cui le curve sono disposte su piani distinti, con ciascun piano definito dal relativo anomaly score (figura 5.4). Le curve che affollano la zona di bassa anomalia hanno zero idraulico nell'intorno della posizione neutra del cassetto e rappresentano valvole critiche o con valori di underlap limitati. Le curve anomale, invece, sono casi limite dove lo zero idraulico è molto distante dalla posizione di zero registrata sul banco di prova oppure valvole che presentano ricoprimenti molto elevati o molto ridotti, come atteso.

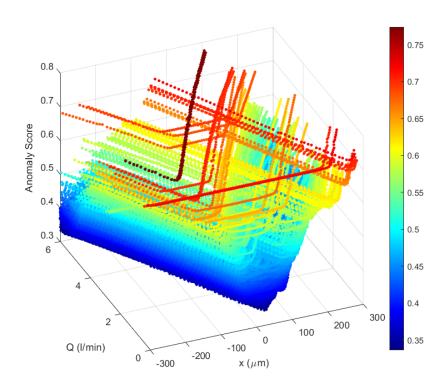


Figura 5.4: Grafico 3D delle curve di portata in funzione del punteggio di anomalia

Per individuare le valvole anomale è possibile creare una tabella che associa all'ID identificativo della valvola il relativo punteggio di anomalia. Facendo ciò si può automatizzare l'individuazione di osservazioni non regolari e risalire ai problemi. Per migliorare la comprensione delle anomalie si genera un grafico in cui vengono

visualizzate le prove idrauliche irregolari (figura 5.5). Analizzando il dataset, esso appare molto regolare e le anomalie risultano essere casi isolati.

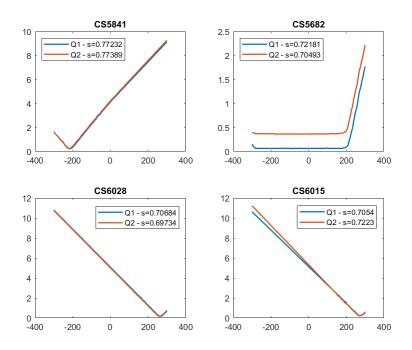


Figura 5.5: Esempio grafici con diversi anomaly score

#### Analisi sulla differenza dei grafici di portata

Attraverso questa analisi si vogliono selezionare le valvole che presentano curve idrauliche differenti tra la porta 1 e la porta 2. Si esegue una preparazione dei dati simile al caso precedente, ma si aggiunge uno step successivo. Si effettua una sottrazione punto per punto fino ad ottenere una matrice composta dalle differenze per ogni curva. Utilizzando queste curve si ripete l'operazione di addestramento del modello. Dall'analisi si individuano nuove criticità che è possibile isolare in una tabella. La visualizzazione permette di ottenere una nuova panoramica (figura ??). Le valvole che presentano criticità, in questo caso, possono essere quelle che non sono nell'ultimo step di lavorazione, ma che sono state inserite erroneamente nel

database. Tramite il valore dell'identificativo è possibile ricollegarsi alla storia delle valvole in questione e conoscerne meglio i dettagli.

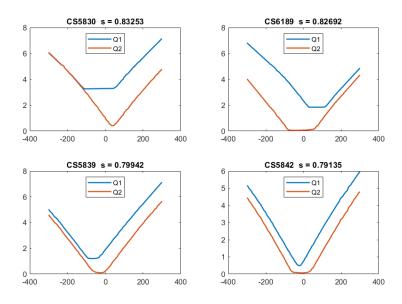


Figura 5.6: Esempi di grafici con anomaly score calcolati sulle differenze

#### 5.3.2 Regressione per la stima dei parametri delle valvole

Come visto nel capitolo 4, sfruttare il modello matematico della valvola per risolvere un problema di ottimizzazione e stimare i parametri incogniti porta a risultati molto accurati. Tuttavia, la risoluzione del problema di ottimizzazione richiede tempo ed elevate risorse computazionali, rendendo il processo poco adatto a un utilizzo su larga scala o in contesti che richiedono risposte in tempi brevi. Per superare questa limitazione, sono stati sviluppati dei modelli di machine learning di regressione. In particolare, sono stati programmati e addestrati diversi modelli di regressione sfruttando sia dati sintetici, generati dal modello di simulazione in Simulink, sia dati sperimentali. L'addestramento è stato eseguito con approcci differenti per confrontare le prestazioni dei vari modelli e identificare la configurazione più efficace in termini di accuratezza e generalizzazione.

Questo approccio consente di stimare rapidamente i parametri incogniti senza dover risolvere il problema di ottimizzazione per ogni nuova curva sperimentale. In questo modo, si ottiene un significativo vantaggio in termini di efficienza computazionale, mantenendo al contempo una buona accuratezza nelle stime.

Per effettuare questa operazione sono stati utilizzati diversi algoritmi di regressione (tabella 5.2) ma quello che ha ottenuto i risultati più soddisfacenti è stato l'algoritmo Gaussian Process che viene utilizzato proprio per la regressione di funzioni sconosciute. Gli algoritmi GP sono particolarmente utili quando i dati campionati sono irregolari perché eccellono nel minimizzare il rumore e interpolare i punti.

Algorithm	Validation RMSE		
Gaussian Process Regression	1.999		
Neural Network	3.193		
Tree Ensemble	3.365		
Efficient Linear	4.875		
Linear Regression	4.908		

Tabella 5.2: RMSE delle predizioni su un set di validazione

#### Gaussian Process

I Gaussian Processes possono essere visti come una generalizzazione multidimensionale della distribuzione normale. Mentre una distribuzione normale descrive una variabile scalare o vettoriale, un GP descrive una distribuzione su funzioni. Questo significa che, invece di assegnare una probabilità a un valore specifico, i GP assegnano una distribuzione a ogni possibile funzione che potrebbe spiegare i dati osservati, [8].

L'idea dei GP è quella di creare una distribuzione normale multivariata<sup>3</sup> che

 $<sup>^3{\</sup>rm Generalizzazione}$  della distribuzione normale (univariata) a dimensioni più elevate

modella la probabilità congiunta dei predittori con quella delle risposte. Una volta costruito il modello, con nuovi predittori si può stimare la risposta più probabile e una deviazione standard che permette di definire un intervallo di confidenza. Si può visualizzare l'idea facendo riferimento alla figura 5.7, che mostra una distribuzione bivariata. Se x rappresenta un predittore e y la corrispondente risposta, si può determinare la probabilità di ottenere un certo valore y dato un particolare x tramite un processo detto condizionamento, che porta alla distribuzione P(Y|X).

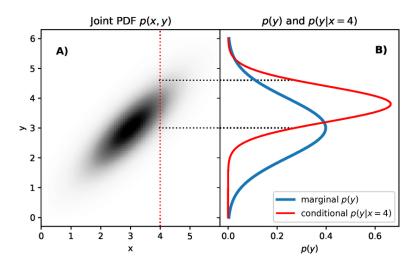


Figura 5.7: Marginalizzazione e condizionamento

La regressione tramite GP parte dalla definizione del problema. Dati dei valori osservati  $X = \{\mathbf{x_1}, \mathbf{x_2}, ... \mathbf{x_N}\}$  e le corrispondenti risposte  $Y = \{\mathbf{y_1}, \mathbf{y_2}, ... \mathbf{y_N}\}$ , si vuole ottenere la distribuzione predittiva  $P(y^*|x^*, X, Y)$ . L'assunzione fondamentale è che la funzione  $f(\mathbf{x})$  sia distribuita come una normale multivariata con un certo vettore delle medie e una matrice di covarianza, costruita tramite una funzione detta kernel. La distribuzione congiunta tra valori osservati Y e quelli da predire  $Y^*$  è:

$$\begin{bmatrix} Y \\ Y^* \end{bmatrix} \sim \mathcal{N} \left( \begin{bmatrix} \mu(X) \\ \mu(X^*) \end{bmatrix}, \begin{bmatrix} K(X, X) & K(X, X^*) \\ K(X^*, X) & K(X, X) \end{bmatrix} \right)$$
(5.2)

dove:

- X sono i predittori di addestramento,
- X\* sono i predittori per valutare il valore atteso,
- $\mu$  è il vettore delle medie,
- $K(x_i, x_j)$  sono gli elementi della matrice di covarianza definiti dalla funzione kernel K.

Il passaggio cruciale dei GP è la costruzione della matrice di covarianza attraverso il kernel. La matrice, infatti, non solo determina la forma della distribuzione probabilistica, ma incide direttamente sulle proprietà della funzione da predire. Il kernel K(x,x') riceve in input due punti x e x' e restituisce la correlazione tra i valori della funzione nei diversi punti dello spazio. Valutando il kernel su ogni coppia di punti di addestramento, si ottiene la matrice di covarianza, che descrive l'influenza relativa di ciascun dato sugli altri. La scelta del kernel è fondamentale poiché determina le proprietà della funzione interpolante e influisce sulla struttura della funzione risultante (5.8).

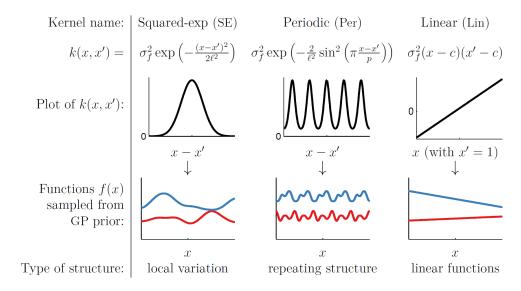


Figura 5.8: Esempi di strutture ottenibili da diversi kernel

L'ultimo passaggio della regressione consiste nell'applicazione del condizionamento, che sfrutta le proprietà delle distribuzioni gaussiane per ottenere la predizione nei punti di interesse. La distribuzione risultante è caratterizzata da una media e una deviazione standard: la media rappresenta il valore atteso della funzione, ossia la stima più probabile della risposta, mentre la deviazione standard quantifica l'incertezza della previsione. Quest'ultima consente di definire un intervallo di confidenza, entro il quale la funzione reale ha alta probabilità di trovarsi.

#### Addestramento con dati sintetici

Tornando al problema iniziale, ovvero quello di stimare i parametri incogniti a partire dai test idraulici, si seguono due approcci di addestramento. Con il primo, si sceglie di utilizzare dati sintetici generati con il modello di simulazione. Con il secondo, si addestra il modello di apprendimento automatico direttamente con i dati delle valvole reali (i dati incogniti sono comunque ricavati risolvendo il problema di ottimizzazione). Utilizzando il modello descritto nel Capitolo 4, è stato sviluppato uno script in grado di generare casualmente i valori di ricoprimento e zero idraulico all'interno di un intervallo predefinito per ciascuna camera di controllo della valvola:

$$-200\mu m < hz < 200\mu m$$

$$-100\mu m < covering < 100\mu m$$

Questa scelta è motivata dalla necessità di esplorare un ampio spettro di configurazioni possibili, comprese le condizioni limite, al fine di costruire un modello di regressione sufficientemente generale e robusto. Un modello con un dataset ben bilanciato e rappresentativo consente di ottenere una maggiore capacità di generalizzazione, rendendo possibile la stima accurata dei parametri anche in condizioni non esplicitamente presenti nei dati di addestramento. Una volta generati i valori di ricoprimento e zero idraulico, il programma crea le corrispondenti curve idrauliche

per la valvola fittizia. I dati ottenuti vengono quindi archiviati in una tabella che associa ogni curva idraulica ai parametri geometrici imposti.

Una volta costruito il dataset artificiale, si procede a un'operazione di preprocessing analoga a quella descritta nel paragrafo 5.3.1, con l'obiettivo di rendere i dati omogenei e direttamente utilizzabili per l'addestramento. In particolare, le curve sono state ricampionate su un dominio uniforme, garantendo che ogni curva idraulica abbia lo stesso numero di punti e che le caratteristiche distintive siano preservate. Inoltre, eventuali valori NaN presenti nei dati sono stati sostituiti mediante interpolazione, evitando la perdita di informazioni e migliorando la qualità complessiva del dataset. Questa fase di elaborazione è cruciale per ridurre possibili anomalie nei dati e per garantire che il modello di regressione lavori su informazioni coerenti e ben strutturate.

Prima di procedere con l'addestramento, una porzione del dataset sintetico è stata riservata per una fase preliminare di validazione. Questo approccio consente di monitorare le prestazioni del modello su dati non utilizzati in fase di apprendimento, permettendo di ottimizzare l'accuratezza predittiva.

L'addestramento del modello è stato eseguito in un nuovo script utilizzando la funzione fitrgp, che implementa un processo gaussiano per la regressione. Per il kernel sono stati scelti il Matérn 5/2 e lo Squared Exponential, poiché entrambi offrono un buon compromesso tra capacità di adattamento ai dati e regolarizzazione del modello. Il kernel Matérn 5/21 introduce una maggiore flessibilità nella modellazione delle relazioni non lineari rispetto a kernel più rigidi, come il kernel quadratico o il RBF (Radial Basis Function), mentre lo Squared Exponential garantisce una modellazione più liscia e continua delle variazioni nei dati. L'uso combinato di questi kernel consente di bilanciare complessità e generalizzazione, ottenendo modelli capaci di adattarsi efficacemente ai dati senza incorrere in fenomeni di overfitting.

Completata la fase di addestramento, è possibile effettuare una predizione su nuovi dati. La funzione predict associata al modello GP restituisce tre possibili output, i quali sono descritti nella tabella 5.3 e permettono di valutare diversi aspetti delle previsioni del modello.

Variabile	Descrizione
ypred	Vettore contenente i valori previsti dal modello GPR (fitrgp)
	per ciascun punto di input. Ogni elemento rappresenta la sti-
	ma della risposta media del modello per un dato di ingresso.
ysd	Vettore delle deviazioni standard associate alle predizioni. Va-
	lori più alti indicano una maggiore incertezza nel modello ri-
	spetto a una particolare osservazione.
yint	Matrice con due colonne che rappresentano l'intervallo di con-
	fidenza al 95% per le predizioni. La prima colonna contiene
	i limiti inferiori, mentre la seconda colonna contiene i limiti
	superiori.

Tabella 5.3: Output della funzione predict per un modello GPR (fitrgp)

Il modello è stato sottoposto a un test preliminare sulla porzione di dati riservata alla validazione. Questa operazione ha permesso di valutare le prestazioni predittive del modello e di verificare la coerenza delle stime rispetto ai dati sintetici generati inizialmente. I risultati, illustrati nella figura 5.9, dimostrano che il modello è in grado di riprodurre con buona accuratezza i valori di ricoprimento e zero idraulico nel contesto del dataset di validazione. I modelli addestrati sono stati quindi salvati in un file .mat, in modo da poter essere successivamente utilizzati nella fase di test su dati sperimentali.

A questo punto i modelli caricati in un nuovo script sono utilizzati per effettuare previsioni sui dati provenienti da prove idrauliche reali. Le performance del modello si sono rivelate molto inferiori rispetto a quelle ottenute sul dataset di validazione, figura 5.10. Questa discrepanza può essere attribuita a molteplici cause: tra le principali, vi è la presenza di rumore sperimentale nei dati acquisiti, dovuto a incertezze di misura, tolleranze costruttive e variazioni nelle condizioni di prova. Un'altra possibile causa di errore risiede nelle semplificazioni adottate durante la

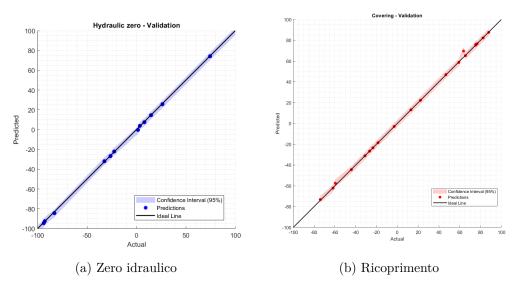


Figura 5.9: Validazione delle predizioni di zero idraulico e ricoprimento nel dataset sintetico

generazione del dataset artificiale: sebbene il modello di simulazione sia stato sviluppato per riprodurre fedelmente il comportamento delle valvole, è possibile che alcune caratteristiche o fenomeni non lineari non siano stati completamente catturati, portando a una discrepanza tra la simulazione e la realtà. È interessante osservare che, al contrario di quanto accade durante la validazione, in cui le previsioni sono accurate per entrambi i valori che si vogliono stimare, è molto più difficile stimare il ricoprimento a partire dai test condotti su valvole reali.

Nonostante queste limitazioni, l'approccio seguito ha dimostrato di essere un valido strumento per stimare preliminarmente i parametri geometrici delle valvole, fornendo risultati coerenti in diversi scenari. È possibile utilizzare questo modello per effettuare stime grossolane di grandi dataset e analizzare nel dettaglio i casi che sembrano problematici. A conferma di ciò si riportano i grafici di distribuzione dell'errore relativo (figura 5.11), e si nota che questo si riduce per valori estremi, mentre presenta un massimo in corrispondenza di valori vicini allo zero.

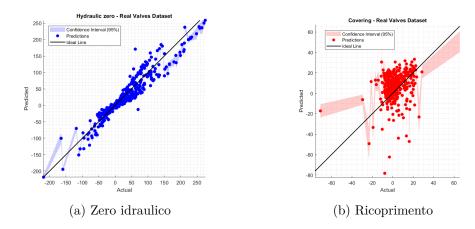


Figura 5.10: Predizioni di zero idraulico e ricoprimento con modello addestrato su dati sintetici

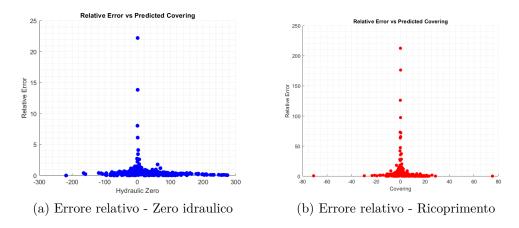


Figura 5.11: Distribuzione dell'errore relativo di zero idraulico e ricoprimento con modello addestrato su dati sintetici

#### Risultati ottenuti con dati del modello fisico

Osservando che il modello addestrato con dati sintetici non garantisce risultati ottimali, è stato effettuato un nuovo addestramento utilizzando esclusivamente dati sperimentali ottenuti da test di portata su valvole reali. Il processo di addestramento ha seguito la stessa metodologia impiegata nel caso dei dati sintetici, assicurando così un confronto diretto tra le due soluzioni. Tuttavia, mentre nel primo caso era possibile generare un ampio dataset simulato per il training e utilizzare i dati

reali per valutare le performance, in questo scenario la validazione del modello è stata condotta esclusivamente su un sottoinsieme di dati reali, selezionato e rimosso preventivamente dal database di riferimento per evitare contaminazioni nei risultati.

L'analisi delle prestazioni evidenzia un netto miglioramento rispetto al modello basato esclusivamente su dati sintetici: le previsioni risultano più coerenti con i valori attesi, segnale che il modello ha appreso con maggiore efficacia le caratteristiche dei dati sperimentali. Questo risultato suggerisce che la conoscenza diretta di dati acquisiti da test reali permette di ridurre il divario tra le simulazioni e il comportamento effettivo del sistema. Tuttavia, sebbene l'accuratezza ottenuta sia superiore rispetto alla versione precedente, il livello di fedeltà raggiunto non è ancora sufficiente per sostituire il modello di simulazione basato sulla fisica. Permangono infatti discrepanze nelle previsioni, attribuibili alla complessità intrinseca del sistema e alla presenza di fenomeni non completamente catturati dal modello di regressione.

I risultati illustrati nei grafici 5.12 e 5.13 mostrano che il modello offre una buona affidabilità nella stima dello zero idraulico, ma riscontra difficoltà nella previsione del ricoprimento. In particolare, la distribuzione degli errori evidenzia una concentrazione dell'errore relativo intorno allo zero. Questo comportamento indica che, sebbene il modello riesca a catturare alcune caratteristiche chiave del sistema, persistono margini di miglioramento nella rappresentazione delle variazioni più sottili, specialmente nelle zone critiche per la definizione del ricoprimento.

#### Risultati ottenuti con un dataset combinato

Per valutare ulteriormente le capacità dei modelli di regressione, è stato condotto un nuovo studio in cui il modello è stato addestrato su un dataset combinato, composto sia da dati sperimentali sia da dati sintetici. Per garantire una maggiore aderenza alla realtà fisica del sistema, ai dati sperimentali è stato assegnato un peso superiore rispetto a quelli sintetici durante la fase di training. Poiché in MATLAB

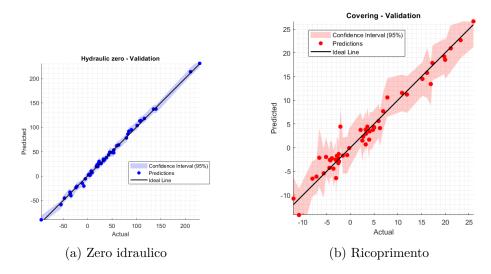


Figura 5.12: Predizioni di zero idraulico e ricoprimento con modello addestrato su dati reali

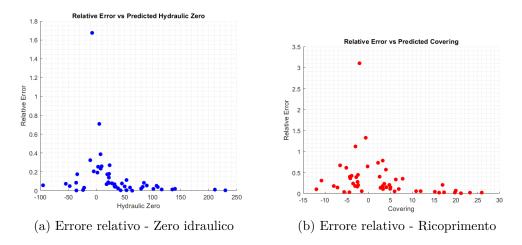


Figura 5.13: Distribuzione dell'errore relativo di zero idraulico e ricoprimento con modello addestrato su dati reali

non è possibile attribuire un peso diretto alle osservazioni, questo è stato fatto in modo indiretto, replicando le osservazioni reali un numero di volte pari al peso assegnato. Infine, il modello è stato testato esclusivamente su dati sperimentali per valutarne l'efficacia.

I risultati ottenuti mostrano che, nonostante il modello sia stato addestrato

su una percentuale ridotta del set di dati sperimentali, le sue prestazioni risultano comparabili a quelle del modello addestrato interamente su dati reali. Questo
suggerisce che l'integrazione di dati sintetici opportunamente bilanciati non compromette l'accuratezza delle previsioni, ma anzi consente di ridurre la necessità di
dati sperimentali, il cui reperimento può essere costoso e complesso.

L'approccio adottato presenta vantaggi significativi anche in altri contesti, specialmente nei casi in cui i dati sperimentali siano limitati o difficili da ottenere. L'uso combinato di dati reali e sintetici permette infatti di sfruttare la flessibilità dei modelli generativi per ampliare il dataset disponibile, migliorando la capacità del modello di generalizzare a nuovi scenari operativi. Inoltre, questa strategia può essere utile in ambiti in cui le simulazioni fisiche sono particolarmente accurate, consentendo di creare dataset sintetici altamente rappresentativi della realtà e riducendo la dipendenza da test sperimentali su larga scala.

Per sintetizzare i risultati ottenuti con i vari modelli, si riporta la tabella riassuntiva 5.4. Dall'analisi dei risultati emerge che le performance del modello migliorano con l'aumento della quantità di dati reali, ma il miglioramento non segue un andamento lineare: per lo zero idraulico, anche una porzione ridotta di dati sperimentali porta a un miglioramento significativo, mentre per il ricoprimento questo effetto non è immediato.

Questo comportamento suggerisce che, per alcune grandezze, il modello è in grado di generalizzare efficacemente anche con un set limitato di dati reali, mentre per altre variabili è necessaria una quantità maggiore di osservazioni affinché il modello riesca a catturare le relazioni sottostanti con sufficiente accuratezza. Tale fenomeno potrebbe essere dovuto alla diversa sensibilità delle variabili al rumore sperimentale o alla complessità delle relazioni fisiche che il modello deve apprendere. Generalizzando a contesti diversi, si può concludere che l'inclusione di dati sperimentali nell'addestramento ha effetti positivi sulle prestazioni del modello, ma la quantità di dati da integrare deve essere calibrata attentamente in funzione della

specifica grandezza da predire.

% Real	RMSE HZ	MSE HZ	Rel. Err. HZ	RMSE Cov.	MSE Cov.	Rel. Err. Cov.
0% (Only Synth. Data)	20.04	16.01	0.359	13.36	9.80	2.061
15%	6.64	3.61	0.285	4.67	3.23	1.799
<b>25</b> %	4.97	3.58	0.246	5.05	3.00	1.349
<b>50</b> %	5.56	2.98	0.233	3.59	2.52	1.381
80%	3.82	3.02	0.196	2.79	2.17	1.360
<b>95</b> %	4.13	3.52	0.117	1.98	1.61	0.461
Baseline (Only Real Data)	3.57	2.75	0.135	1.81	1.30	0.335

Tabella 5.4: Performance del modello con varie inclusioni di dati reali

# 5.3.3 Deep Learning per prevenire derive nel processo produttivo

Un'ulteriore possibilità di impiego del machine learning riguarda il forecasting di serie temporali, ovvero la previsione di valori futuri basata sulla storia dei dati. Nel programma descritto in questo paragrafo viene utilizzato un algoritmo di deep learning per prevedere l'andamento temporale dei dati stimati ottenuti dal modello Simulink illustrato nel capitolo 4. Prima di approfondire l'applicazione pratica, è opportuno fornire una breve introduzione alle reti neurali, con particolare attenzione al livello LSTM, [2].

Le reti neurali artificiali sono modelli matematici ispirati alla struttura e al funzionamento dei sistemi nervosi biologici, composti da una vasta gamma di neuroni connessi in una struttura complessa. Una rete neurale artificiale è composta da unità specifiche che compiono operazioni differenti. Alcune ricevono segnali in input, altre comunicano risposte in output ed altre ancora lavorano solo entro la rete neurale e sono dette unità nascoste, figura 5.14. Ogni unità è detta percettrone o neurone artificiale e compie semplici operazioni matematiche: somma i segnali ricevuti moltiplicati per un opportuno peso, somma un valore di bias e passa il risultato a una funzione di attivazione che introduce una non linearità:

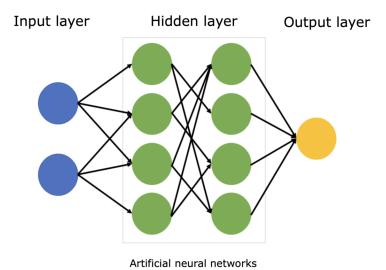


Figura 5.14: Rete neurale artificiale

$$g\left(\sum_{i=0}^{N} w_i x_i + b\right) \tag{5.3}$$

dove:

- g è la funzione di attivazione non lineare,
- $w_i$  è il peso associato all'input,
- $x_i$  è il valore dell'input, e
- b è il valore del bias.

I valori di peso e bias vengono calcolati con l'addestramento della rete neurale. Ogni set di neuroni è detto livello o *layer*, e una rete composta da quattro livelli o più è detta rete neurale profonda o *deep network*.

Per determinare i valori della serie temporale è necessario introdurre un nuovo tipo di livello detto LSTM, ovvero Long Short Term Memory. Queste unità sono necessarie a decidere se è opportuno utilizzare le informazioni apprese dalla serie temporale. Il nome, infatti, suggerisce che sono necessarie per catturare dipendenze sia a breve che a lungo termine nei dati.

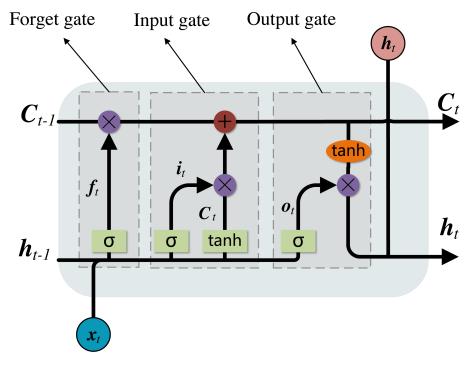


Figura 5.15: Rappresentazione di una cella LSTM.

Nella figura 5.15 è rappresentata una cella LSTM. A ogni istante temporale, la cella riceve un nuovo input  $x_t$ , insieme all'uscita della cella precedente  $h_{t-1}$ , e aggiorna il proprio stato interno  $C_t$ , che funge da memoria a lungo termine. Questo stato viene regolato dinamicamente attraverso tre porte principali: la porta di dimenticanza, la porta di ingresso e la porta di uscita. La porta di dimenticanza decide quali informazioni della memoria precedente  $C_{t-1}$ , devono essere mantenute e quali devono essere scartate. Questo avviene attraverso una funzione di attivazione sigmoide, che restituisce valori compresi tra 0 e 1, dove 0 indica la completa eliminazione dell'informazione e 1 la sua totale conservazione. La porta di ingresso, invece, stabilisce quali nuove informazioni devono essere aggiunte alla memoria. Anche in questo caso si utilizza la sigmoide per filtrare l'ingresso, combinata con una funzione tangente iperbolica (tanh) che trasforma i nuovi dati in valori compresi tra -1 e 1, contribuendo a mantenere la stabilità numerica e a evitare una crescita incontrollata dello stato della cella. Una volta aggiornato lo stato della cella  $C_t$ , la

porta di uscita determina quali parti di questa memoria devono essere utilizzate per calcolare l'output  $h_t$ , ovvero l'informazione che verrà trasmessa al livello successivo della rete o alla successiva iterazione temporale. Anche qui, la sigmoide regola il flusso di informazioni, mentre la tangente iperbolica garantisce che i valori rimangano in un intervallo gestibile. Grazie a questa struttura, le celle sono in grado di preservare informazioni rilevanti per lunghi intervalli di tempo. Questo le rende particolarmente adatte all'analisi di serie temporali e a tutte quelle applicazioni in cui il contesto storico dei dati è cruciale per effettuare previsioni accurate.

#### Applicazione alla stima degli andamenti dei raggi di raccordo

Si sceglie di applicare la tecnica di forecasting sulla serie temporale relativa al raggio di raccordo del cassetto della valvola. Tale parametro, scelto per la sua potenziale correlazione con l'usura degli strumenti di lavorazione, è anch'esso derivato dallo studio compiuto con il modello fisico di capitolo 4. Si sceglie di effettuare l'analisi sui dati filtrati tramite media mobile per catturare i trend piuttosto che i valori specifici. L'analisi di questa grandezza risulta particolarmente interessante perché l'usura degli utensili di lavorazione può introdurre tendenze sistematiche o fenomeni di stagionalità nel processo produttivo. Ad esempio, un graduale degrado degli strumenti potrebbe comportare variazioni lente e progressive nel raggio di raccordo, mentre eventuali cicli di manutenzione potrebbero determinare un andamento ripetitivo nel tempo.

L'obiettivo di questo studio è quello di sfruttare la storia dei dati per prevederne l'andamento futuro, utilizzando modelli basati su reti neurali LSTM, oltre a varianti quali un'architettura a doppio LSTM e una bidirezionale (biLSTM). Di seguito verranno spiegati i vari step implementativi e i benefici associati alle diverse architetture.

Il primo step previsto consiste nel caricamento dei dati, in questo caso la serie temporale contenuta. La serie viene ordinata cronologicamente, creando un vettore te, la serie viene divisa in due insiemi: un training set (75% dei dati) utilizzato per addestrare il modello e un test set (25% dei dati) impiegato per validare la capacità predittiva del modello. Questa suddivisione garantisce che il modello impari dalle informazioni storiche, per poi essere valutato sulla sua capacità di generalizzazione su dati non visti durante l'addestramento. Per migliorare l'efficienza dell'addestramento e stabilizzare il processo di ottimizzazione, i dati del training set vengono normalizzati tramite min-max scaling:

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \tag{5.4}$$

la funzione di normalizzazione, e la sua inversa per la de-normalizzazione, assicurano che i valori si trovino in un range [0, 1] durante l'addestramento, facilitando così il lavoro delle reti neurali. Lo step successivo è quello di dividere i dataset in finestre temporali, per ottimizzare la previsione sfruttando la memoria storica del modello. Per l'analisi dei raggi di raccordo, la finestra temporale che dà i risultati migliori è composta da 25 elementi e il target associato è il valore successivo della serie. Una volta preparati i dati è possibile passare all'addestramento dei modelli. Nella tabella 5.5 sono presenti informazioni sintetiche sulla struttura dei modelli utilizzati e sulle caratteristiche principali. Si può notare la presenza di alcuni livelli di cui non si è discusso in precedenza. Il Dropout Layer è un livello sfruttato durante l'addestramento per regolarizzare le reti neurali e ridurre il rischio di overfitting. Ad ogni iterazione, il layer disattiva casualmente una percentuale di neuroni per impedire di renderla troppo dipendente da specifici neuroni e favorisce una generalizzazione migliore sui dati di test. I Layer ReLU introducono la funzione di attivazione Rectified Linear Unit f(x) = max(0,x) che genera una non-linearità nella rete e aiuta a evitare il problema della scomparsa del gradiente. E utilizzata nei layer nascosti perché migliora la velocità di apprendimento e permette alla rete di modellare relazioni complesse tra i dati.

Modello	Struttura	Caratteristiche
LSTM	Input Sequenza $\rightarrow$ LSTM (128) $\rightarrow$ Dropout (0.2) $\rightarrow$ Fully Connected $\rightarrow$ Output Regressione	Semplice ed efficace nel catturare dipendenze a lungo termine. Minore complessità computazionale, ma potrebbe non catturare pattern complessi o relazioni multi-scala.
Doppio LSTM	Input Sequenza $\rightarrow$ LSTM (128, sequence) $\rightarrow$ Dropout (0.2) $\rightarrow$ LSTM (64, last) $\rightarrow$ Dropout (0.2) $\rightarrow$ Fully Connected $\rightarrow$ Output Regressione	Maggiore capacità di apprendimento gerarchico. Cattura meglio dipendenze temporali complesse, ma con maggiore costo computazionale e rischio di overfitting.
biLSTM	Input Sequenza $\rightarrow$ biLSTM (128) $\rightarrow$ Re- LU $\rightarrow$ Dropout (0.2) $\rightarrow$ Fully Connected $\rightarrow$ Output Regressione	Considera informazioni sia passate che future, utile per serie con dipendenze bidirezionali. Richiede più risorse di calcolo ed è meno vantaggioso in problemi puramente sequenziali ma a volte cattura relazioni non immediate.

Tabella 5.5: Confronto tra le architetture LSTM utilizzate

Il processo di previsione segue una procedura iterativa basata su un approccio di forecasting ricorsivo. Inizialmente, il modello viene reimpostato per eliminare qualsiasi stato memorizzato dall'addestramento precedente e viene aggiornato utilizzando l'ultima sequenza disponibile nel training set. Successivamente, la previsione avviene attraverso un loop ricorsivo, in cui il modello calcola iterativamente il valore successivo della serie temporale. Ad ogni iterazione, la sequenza di input viene aggiornata sostituendo il valore più vecchio con la nuova previsione, permettendo al modello di generare predizioni future basandosi su dati "auto generati". Poiché i dati sono stati normalizzati durante l'addestramento, i valori devono essere riportati alla scala originale mediante una funzione di de-normalizzazione, garantendo che i risultati siano interpretabili nel contesto del problema reale.

Dall'analisi dei risultati ottenuti con i tre modelli implementati emergono differenze significative in termini di accuratezza predittiva e comportamento.

Osservando i grafici di performance, si nota come il modello LSTM standard (Figura 5.16) riesca a catturare il trend generale della serie temporale, mostrando una curva di previsione che segue l'andamento medio dei dati reali. Tuttavia, presenta limitazioni nella capacità di adattarsi alle oscillazioni più rapide, producendo una previsione eccessivamente smussata. L'errore assoluto mostra picchi in corrispondenza dei cambi repentini di direzione della serie, con valori massimi attorno a 0.35.

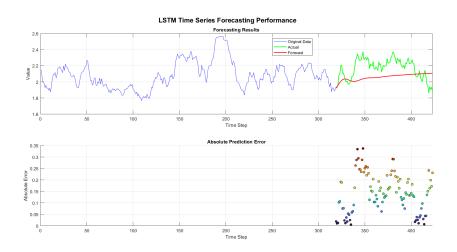


Figura 5.16: Forecasting con rete LSTM

Il modello a doppio LSTM (figura 5.17) offre un miglioramento nella capacità predittiva, come evidenziato dalla traiettoria di previsione che segue con maggiore fedeltà l'andamento reale della serie. Ciò conferma quanto affermato nella tabella 5.5, dove si sottolineava la maggiore capacità di apprendimento gerarchico di questa architettura. Si osserva una moderata riduzione dell'errore nelle fasi intermedie della previsione, sebbene nelle fasi finali si verifichi un incremento dell'errore assoluto che raggiunge valori prossimi a 0.4, suggerendo possibili difficoltà nel mantenere l'accuratezza predittiva su orizzonti temporali estesi.

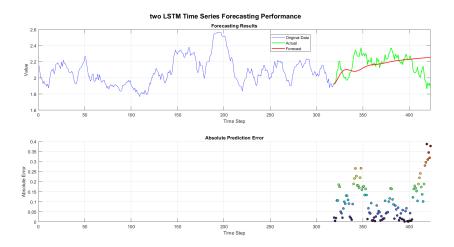


Figura 5.17: Forecasting con rete a due livelli LSTM

Il modello biLSTM presenta un comportamento più articolato. Nella configurazione mostrata in Figura 5.18, si può notare come la rete riesca a seguire con discreta precisione l'andamento iniziale per poi divergere significativamente verso la fine della sequenza, con un aumento dell'errore assoluto fino a valori di 0.6. Questa tendenza alla divergenza riflette la complessità intrinseca dell'architettura bidirezionale, che, pur beneficiando dell'elaborazione in entrambe le direzioni temporali durante l'addestramento, può risultare instabile in fase di previsione ricorsiva quando l'orizzonte previsionale si estende. Particolarmente interessante è osservare come la caratteristica bidirezionalità della rete biLSTM crei forti simmetrie nella previsione che sembrano ricalcare l'andamento della serie temporale, quasi come se la previsione venisse elaborata a ritroso. Questo fenomeno è ancora più evidente nella variante mostrata nella figura 5.19, dove la traiettoria prevista mostra oscillazioni che sembrano "specchiare" pattern precedentemente osservati nella serie storica. Questa tendenza alla simmetria e alla divergenza riflette la complessità intrinseca dell'architettura bidirezionale, che, pur beneficiando dell'elaborazione in entrambe le direzioni temporali durante l'addestramento, può risultare instabile in fase di previsione ricorsiva quando l'orizzonte previsionale si estende.

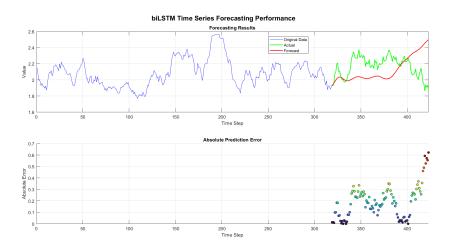


Figura 5.18: Forecasting con rete biLSTM

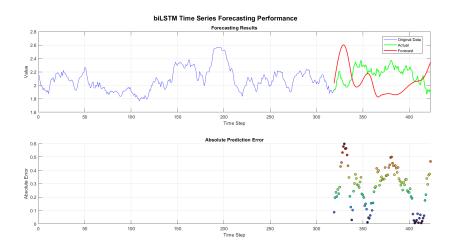


Figura 5.19: Forecasting con rete biLSTM (simmetria)

Risulta evidente come le caratteristiche strutturali delle reti influenzino direttamente i pattern previsionali: l'LSTM standard produce previsioni più stabili ma meno reattive, il doppio LSTM offre un miglior compromesso tra stabilità e adattabilità, mentre il biLSTM, pur potenzialmente vantaggioso per catturare dipendenze temporali complesse, mostra maggiore variabilità e rischio di sovra-adattamento quando utilizzato in modo ricorsivo per previsioni a lungo termine.

Nonostante i risultati ottenuti siano interessanti, l'analisi condotta evidenzia

come la sola storia dei dati non sia sufficiente per ottenere previsioni affidabili nel lungo periodo. Questa difficoltà può essere attribuita sia alla complessità intrinseca del fenomeno, che potrebbe non essere completamente catturata dal modello, sia alla natura dei dati utilizzati. In particolare, il fatto che questi dati derivino già da stime prodotte da un altro modello introduce un ulteriore livello di incertezza e amplifica la complessità del problema.

Nel prossimo paragrafo verrà approfondita l'applicazione del modello a una serie sintetica di dati, permettendo di isolare meglio le variabili e di valutare con maggiore precisione le reali potenzialità del metodo proposto.

#### Validazione della tecnica di previsione su una serie temporale sintetica

Per valutare in modo controllato le capacità predittive dei modelli LSTM, è stato generato un dataset sintetico che riproduce le principali caratteristiche delle serie temporali industriali, combinando stagionalità, rumore e trend di crescita. Questo approccio consente di isolare le componenti fondamentali dei dati reali e di verificare la capacità dei modelli di identificare relazioni non lineari in un contesto noto.

La serie sintetica è costruita sovrapponendo quattro elementi chiave:

- una doppia oscillazione sinusoidale che simula una stagionalità complessa,
- un rumore gaussiano a bassa intensità che riproduce la variabilità dei dati sperimentali,
- una funzione di crescita attivata dopo cinque mesi,
- uno shift costante.

La Figura 5.20 illustra la scomposizione del segnale. Un andamento di questo tipo potrebbe rappresentare, ad esempio, il comportamento di un processo industriale soggetto a variazioni cicliche e usura progressiva. In particolare, la transizione tra la fase inizialmente stazionaria e la successiva crescita può essere interpretata come

l'effetto cumulativo dell'usura degli utensili, mentre le sinusoidi rappresentano cicli operativi ricorrenti.

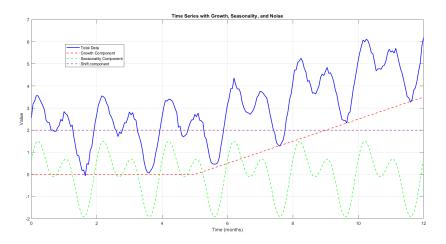


Figura 5.20: Componenti della serie temporale sintetica

L'analisi segue una sequenza strutturata. Inizialmente, il tasso di crescita viene calcolato derivando numericamente i dati, applicando una media mobile per attenuare il rumore e il calcolo delle differenze prime per isolare la componente di trend. I dati vengono quindi suddivisi in training set (75% della serie) e test set (25%), preservando l'ordine temporale per rispettare la struttura sequenziale. Una normalizzazione min-max trasforma i valori nell'intervallo [0,1], migliorando la stabilità della rete durante l'addestramento. Come nel caso precedente, le sequenze di inputoutput sono organizzate in finestre temporali, dove ciascuna finestra rappresenta lo stato storico necessario per la predizione del passo successivo. I modelli utilizzati per la previsione sono gli stessi descritti nel paragrafo precedente: architettura LSTM, doppio LSTM e biLSTM.

Dall'analisi dei nuovi risultati emerge una chiara gerarchia prestazionale tra i modelli implementati.

Il modello LSTM standard (figura 5.21) presenta un comportamento relativamente stabile, con una previsione che segue il trend generale della serie pur manifestando una tendenza al livellamento. Particolarmente evidente è il picco di errore che però si riduce nuovamente nelle fasi finali della previsione. Questo è un segno che il modello non riesce a catturare le relazioni più complesse della stagionalità ma apprende il trend complessivo. L'LSTM standard, con la sua struttura a singolo livello, tende a convergere verso un comportamento medio della serie, sacrificando la capacità di riprodurre oscillazioni ad alta frequenza.

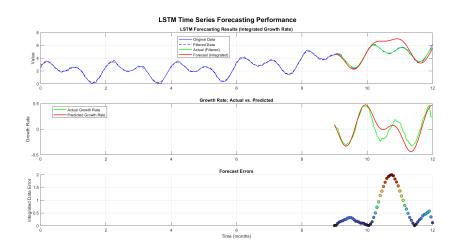


Figura 5.21: Forecasting della serie sintetica con rete LSTM

Il modello a doppio LSTM nella sua prima configurazione (figura 5.22), caratterizzata da una finestra temporale inferiore, mostra significative difficoltà predittive nel catturare l'andamento di crescita dei dati, seppur catturando il pattern periodico. La configurazione del doppio LSTM, limitata da una finestra temporale ristretta, soffre probabilmente di un insufficiente contesto storico per elaborare previsioni accurate. Questa carenza informativa si traduce in una sorta di "miopia predittiva" che impedisce al modello di cogliere pattern a lungo termine, fondamentali per anticipare correttamente l'evoluzione della serie. La seconda configurazione del doppio LSTM (figura 5.22), implementata con una finestra temporale più ampia,

offre risultati decisamente superiori.

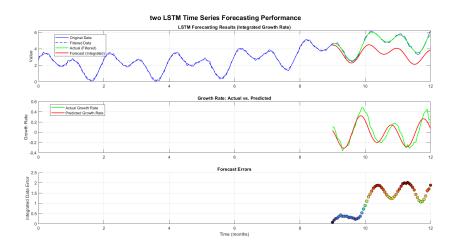


Figura 5.22: Forecasting a due livelli LSTM (finestra temporale ridotta)

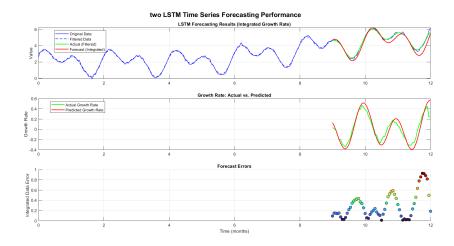


Figura 5.23: Forecasting a due livelli LSTM (finestra temporale più larga)

Infine, il modello biLSTM (immagine 5.24) si distingue per l'ottima capacità di catturare informazioni. Il pattern dell'errore è particolarmente interessante perché non presenta oscillazioni come nei casi precedenti, ma una crescita progressiva. Il comportamento distintivo del biLSTM può essere attribuito alla sua capacità di elaborare la sequenza in entrambe le direzioni temporali. Questa bidirezionalità consente al modello di contestualizzare ogni punto della serie sia rispetto al passato

che al futuro durante la fase di addestramento, creando rappresentazioni interne più ricche.

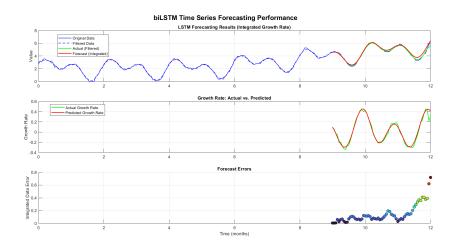


Figura 5.24: Forecasting della serie sintetica con rete biLSTM

I risultati mostrano che i modelli sono in grado di catturare efficacemente sia la stagionalità sia la transizione verso la crescita esponenziale, con un errore complessivamente contenuto. L'integrazione delle previsioni ricostruisce fedelmente l'andamento globale del segnale, con scostamenti minimi nella fase stazionaria e lievi divergenze nei picchi stagionali, dove le rapide variazioni di pendenza rappresentano una sfida critica per qualsiasi modello predittivo. Nonostante le prestazioni complessivamente positive, emergono due limitazioni intrinseche. Da un lato, gli errori cumulativi nell'integrazione delle previsioni possono amplificare le discrepanze su orizzonti temporali estesi, specialmente in presenza di trend a crescita rapida. Dall'altro, elevati livelli di rumore degradano la qualità delle previsioni, rendendo necessarie strategie di filtraggio più efficaci. Tuttavia, la capacità del modello di fornire previsioni accurate nonostante la presenza di componenti stagionali, trend e disturbi casuali conferma l'efficacia dell'approccio LSTM per l'analisi di serie temporali industriali, anche in assenza di un modello fisico. Questi risultati incoraggianti, uniti alla flessibilità dimostrata nel gestire diverse tipologie di crescita,

rappresentano una base metodologica solida per applicazioni in contesti reali. Sebbene la maggiore complessità dei dati industriali richieda ulteriori accortezze, la validità della proposta rimane confermata.

## Capitolo 6

## Conclusioni

Il lavoro svolto in questa tesi ha portato allo sviluppo di un modello numerico per la simulazione del comportamento idraulico della Main Control Valve del Main Rotor Actuator dell'elicottero AW169. Questo modello è stato poi utilizzato come uno strumento di misura indiretto, capace di estrarre informazioni da veri test idraulici per stimare grandezze altrimenti molto difficili da misurare con metodi diretti tradizionali. L'approccio adottato ha combinato una modellazione fisicomatematica con la risoluzione di problemi di ottimizzazione per ottenere una stima accurata dei parametri geometrici incogniti.

Il modello è stato sviluppato in ambiente MATLAB Simulink, sfruttando le equazioni che descrivono il flusso attraverso orifizi e sezioni anulari. Sono stati considerati due regimi di flusso principali: l'efflusso dominato dalle forze d'inerzia, modellato con la legge di flusso potenziale attraverso un orifizio, e il flusso laminare a basso numero di Reynolds, descritto dall'equazione di Hagen-Poiseuille. Parallelamente, la tesi ha sottolineato l'influenza delle caratteristiche costruttive della valvola sulle prestazioni dinamiche all'interno di un sistema servoattuato.

La flessibilità del modello consente la simulazione del comportamento della valvola in diverse configurazioni, tra le quali figurano prove sperimentali standard quali test di *Flow Gain* e di *Pressure Gain*. L'integrazione con tecniche di ottimizzazione ha permesso di calibrare il modello sulla base di dati reali, migliorando l'affidabilità dello stesso e rendendolo capace della stima dei parametri incogniti.

Oltre al modello fisico, l'elaborato illustra alcune possibili applicazioni del machine learning alle realtà industriali. I dati a disposizione sono stati integrati con algoritmi AI per identificare anomalie nelle componenti rispetto agli standard produttivi, prevedere parametri critici ed effettuare previsioni legate all'andamento dei dati in modo da affrontare preventivamente criticità future nei processi industriali.

#### 6.1 Risultati ottenuti

L'analisi dei risultati ha confermato la validità del modello sviluppato. I confronti tra le curve simulate e i dati sperimentali hanno mostrato un'elevata corrispondenza, con errori molto contenuti nelle varie configurazioni costruttive della valvola.

Per quanto riguarda il Flow Gain, il modello ha replicato in maniera accurata il comportamento della valvola nelle diverse configurazioni di ricoprimento (overlap, underlap e critica). I parametri stimati, derivando da considerazioni fisiche e da un processo di calibrazione basato su dati sperimentali, possono ritenersi affidabili e rappresentativi della realtà operativa del componente.

In aggiunta al modello fisico, sono state implementate tre strategie di analisi dei dati di produzione basate sul machine learning per dimostrare come questi approcci possano essere utili nell'analisi di dati industriali, migliorando l'interpretazione dei risultati:

• Identificazione di anomalie tramite unsupervised learning: l'uso di algoritmi basati su Isolation Forest ha permesso di individuare valvole con caratteristiche fuori standard a partire dalle curve idrauliche, contribuendo a una classificazione automatizzata delle componenti non conformi.

- Regressione per la stima dei parametri con supervised learning: per velocizzare l'analisi dei dati e mostrare le potenzialità degli algoritmi black-box basati su ML, sono stati implementati modelli di regressione basati su Gaussian Process utilizzando tre approcci distinti: dati sintetici da Simulink, dati sperimentali e un approccio ibrido che combina entrambi. I risultati ottenuti mostrano una buona capacità di previsione dei parametri incogniti, con il vantaggio principale di consentire un'elaborazione rapida anche su dataset di grandi dimensioni.
- Modelli predittivi per l'analisi delle derive produttive tramite Deep Learning: modelli basati su reti neurali LSTM sono stati applicati all'analisi delle serie temporali dei dati di produzione. L'analisi è stata effettuata su dati reali e validata su una serie temporale reale, dimostrando la capacità del modello di prevedere l'evoluzione dei parametri produttivi e individuare derive significative.

L'integrazione di queste tecniche ha evidenziato come l'utilizzo combinato di modelli fisici e algoritmi di machine learning possa trasformare l'analisi dei dati di produzione da un processo diagnostico a uno strumento intelligente e predittivo. Questa sinergia permette lo sviluppo di strategie avanzate di controllo qualità e ottimizzazione dei processi produttivi, contribuendo a una maggiore efficienza.

#### 6.2 Applicazioni future

I risultati ottenuti dimostrano il potenziale della fusione tra modellazione fisicomatematica e intelligenza artificiale nell'analisi e ottimizzazione dei componenti idraulici. Questo approccio non solo migliora il processo di progettazione e controllo qualità, ma apre la strada a nuove strategie di automazione intelligente nel settore aeronautico e industriale.

#### 6.2.1 Evoluzione del modello simulativo

Il modello sviluppato può essere ulteriormente esteso e integrato in simulazioni più complesse, come quella dell'intero servoattuatore. Questo lo rende utile sia in fase progettuale, per supportare la realizzazione di nuovi prodotti con simulazioni fedeli alla realtà, sia come strumento diagnostico per l'analisi della produzione, contribuendo al monitoraggio della qualità e alla riduzione delle non conformità. Inoltre, l'approccio di ottimizzazione basato sui dati potrebbe essere applicato anche ad altre componenti aeronautiche, ampliando il campo di utilizzo del modello e fornendo nuove possibilità di ottimizzazione nei processi industriali.

#### 6.2.2 Applicazioni dell'analisi con autoapprendimento

L'uso del machine learning nel contesto della produzione aeronautica apre interessanti prospettive per il monitoraggio in tempo reale e la manutenzione predittiva. L'analisi avanzata dei dati consentirebbe di anticipare potenziali guasti e identificare criticità prima che si manifestino, trasformando i dati in uno strumento di prognostica.

Inoltre, sfruttando la storicità dei dati raccolti sulle componenti, è possibile implementare strategie di manutenzione adattiva, che superano i tradizionali interventi programmati e consentono una gestione dinamica delle risorse. Questo approccio permette di migliorare l'affidabilità del sistema, ridurre i costi di manutenzione e aumentare la sicurezza operativa.

# Ringraziamenti

 ${\bf Ringraziamenti.}$ 

## Bibliografia

- [1] Federal Aviation Administration (FAA). Helicopter Flying Handbook. New York, NY: Skyhorse Publishing, 2012.
- [2] Khalid Albeladi, Bilal Zafar e Abdullah Mueen. «Time Series Forecasting Using LSTM and ARIMA». In: International Journal of Advanced Computing (2023). URL: https://www.academia.edu/download/102938576/Paper\_33-Time\_Series\_Forecasting\_using\_LSTM\_and\_ARIMA.pdf.
- [3] Michael W. Berry, Azlinah Mohamed e Bee Wah Yap. Supervised and Unsupervised Learning for Data Science. Springer, 2020. DOI: 10.1007/978-3-030-22475-2. URL: https://link.springer.com/content/pdf/10.1007/978-3-030-22475-2.pdf.
- [4] Giuseppe Ciaburro. *MATLAB for Machine Learning*. English. 2nd. Birmingham, UK: Packt Publishing, 2024. ISBN: 9781835087695.
- [5] T. F. Coleman e Yuying Li. «An Interior, Trust Region Approach for Non-linear Minimization Subject to Bounds». In: SIAM Journal on Optimization 6.2 (1996), pp. 418–445. DOI: 10.1137/0806023.
- [6] Paulina Gackowiec. «General overview of maintenance strategies concepts and approaches». In: Multidisciplinary Aspects of Production Engineering 2 (2019), pp. 126–139. DOI: 10.2478/mape-2019-0013.

- [7] D. Gonzalez-Jimenez et al. «Machine Learning-Based Fault Detection and Diagnosis of Faulty Power Connections of Induction Machines». In: *Energies* 14.16 (2021), p. 4886. DOI: 10.3390/en14164886. URL: https://doi.org/10.3390/en14164886.
- [8] Jochen Gortler, Rebecca Kehlbeck e Oliver Deussen. «A Visual Exploration of Gaussian Processes». In: *Distill* (2019). https://distill.pub/2019/visual-exploration-gaussian-processes. DOI: 10.23915/distill.00017.
- [9] Jui-Chan Huang et al. «Application and Comparison of Several Machine Learning Algorithms and Their Integration Models in Regression Problems». In: Neural Computing and Applications 32.10 (2020), pp. 5461–5469.
- [10] J. Gordon Leishman. Principles of Helicopter Aerodynamics. 2nd. Cambridge,UK: Cambridge University Press, 2006.
- [11] Yi Li et al. «Data-driven health estimation and lifetime prediction of lithiumion batteries: A review». In: Renewable and Sustainable Energy Reviews 113 (2019), p. 109254. DOI: 10.1016/j.rser.2019.109254.
- [12] Noah D. Manring e Roger C. Fales. Hydraulic Control Systems. Hoboken,
   NJ: John Wiley & Sons, Inc., 2019. ISBN: 9781119416470. DOI: 10.1002/
   9781119418528. URL: https://doi.org/10.1002/9781119418528.
- [13] MathWorks. Optimization Problem Formulation for Parameter Estimation.

  Accessed: March 22, 2025. 2024. URL: https://it.mathworks.com/help/
  sldo/ug/optimization-problem-formulation-for-parameter-estimation.
  html.
- [14] Herbert E. Merritt. *Hydraulic Control Systems*. New York: John Wiley & Sons, 1967.

- [15] M. Nacchia et al. «A Systematic Mapping of the Advancing Use of Machine Learning Techniques for Predictive Maintenance in the Manufacturing Sector». In: Applied Sciences 11.6 (2021), p. 2546. DOI: 10.3390/app11062546. URL: https://doi.org/10.3390/app11062546.
- [16] Andrea Nesci et al. «Detection and Prognosis of Propagating Faults in Flight Control Actuators for Helicopters». In: Aerospace 7.3 (feb. 2020), p. 20. DOI: 10.3390/aerospace7030020.
- [17] Gareth D. Padfield. Helicopter Flight Dynamics: Including a Treatment of Tiltrotor Aircraft. Hoboken, NJ: John Wiley & Sons, 2018. ISBN: 9781119401056. DOI: 10.1002/9781119401087.
- [18] Michael Paluszek, Stephanie Thomas e Eric Ham. *Practical MATLAB Deep Learning*. 2nd. Apress, 2022. URL: https://www.perlego.com/book/4514073/practical-matlab-deep-learning-a-projectsbased-approach-pdf.
- [19] John M. Seddon e Simon Newman. *Basic Helicopter Aerodynamics*. 3rd. Aerospace Series. Hoboken, NJ: Wiley, 2011.
- [20] Radhey Shyam e Riya Chakraborty. «Machine Learning and Its Dominant Paradigms». In: *Journal of Advancements in Robotics* 8.2 (2021), pp. 1–10.
- [21] Massimo Sorli e Giuseppe Quaglia. Meccatronica: Le basi della meccatronica. Struttura dei dispositivi di attuazione controllata. Caratteristiche statiche e dinamiche degli strumenti. Epics, 2017, p. 248. ISBN: 8894802078.
- [22] Duqiang Wu, Richard Burton e Greg Schoenau. «An Empirical Discharge Coefficient Model for Orifice Flow». In: *International Journal of Fluid Power* 3.3 (2002), pp. 13–19.
- [23] Minglan Xiong et al. «Digital twin-driven aero-engine intelligent predictive maintenance». In: *The International Journal of Advanced Manufacturing Technology* 114 (2021), pp. 1389–1402. DOI: 10.1007/s00170-021-06763-3.

[24] S. Zhong et al. «A Novel Unsupervised Anomaly Detection for Gas Turbine Using Isolation Forest». In: 2019 IEEE International Conference on Cyber-Enabled Distributed Computing and Knowledge Discovery (CyberC). 2019, pp. 275–282. DOI: 10.1109/CyberC.2019.00055. URL: https://ieeexplore.ieee.org/abstract/document/8819409/.