

UNIVERSITÀ DEGLI STUDI DI PADOVA

DIPARTIMENTO DI INGEGNERIA INDUSTRIALE

CORSO DI LAUREA MAGISTRALE IN  
INGEGNERIA AEROSPAZIALE  
CURRICULUM AERONAUTICO

**Analisi degli impatti obliqui su pannelli in materiale  
composito mediante reti neurali**

*Relatore:* PROF. Mirco Zaccariotto

*Laureando:*

Marco Fracas

*Matricola:*

1242061

Anno Accademico 2023/2024



# Indice

<b>1</b>	<b>Introduzione</b>	<b>1</b>
<b>2</b>	<b>Materiali Compositi</b>	<b>5</b>
2.1	Proprietà . . . . .	7
2.1.1	Proprietà meccaniche di una lamina . . . . .	9
2.2	Difetti caratteristici dei materiali compositi . . . . .	13
2.3	Tipi di danno . . . . .	13
2.4	Meccanismi di cedimento . . . . .	15
2.4.1	Rottura per trazione . . . . .	16
2.4.2	Rottura per compressione . . . . .	17
2.4.3	Rottura a fatica . . . . .	18
2.4.4	Rottura da impatto . . . . .	18
2.5	Criteri di Failure . . . . .	20
2.5.1	Criterio di Failure della lamina . . . . .	20
2.5.2	Criterio di Failure Tsai-Hill . . . . .	21
2.5.3	Criterio di Failure Tsai-Wu . . . . .	21
2.6	Pannelli irrigiditi . . . . .	22
<b>3</b>	<b>Machine Learning</b>	<b>25</b>
3.1	Tipologie di Machine Learning . . . . .	26
3.1.1	Panoramica degli algoritmi di Machine Learning . . . . .	28
3.2	Reti Neurali Artificiali e Convolutionali . . . . .	29
3.2.1	Reti Neurali Artificiali . . . . .	30
3.2.2	Reti Neurali Convolutionali . . . . .	33
3.3	Addestramento e Metriche . . . . .	37
<b>4</b>	<b>Structural Health Monitoring</b>	<b>41</b>
4.1	Tipo di monitoraggio di danni da impatto . . . . .	42
4.2	Valutazione tipo di impatto . . . . .	44

4.2.1	Forza teorica di delaminazione per impatti di grandi masse	46
4.3	Metodologie SHM	48
4.3.1	Tecniche Attive	48
4.3.2	Tecniche Passive	51
4.4	Tecniche adottate	54
<b>5</b>	<b>Modello FEM</b>	<b>55</b>
5.1	Geometria del modello	56
5.2	Materiali	57
5.3	Posizione dei sensori	58
5.4	Mesh	63
5.5	Steps della simulazione	64
5.6	Output	65
5.7	Verifica del modello	67
5.7.1	Applicazione del filtro	69
5.8	Impatti inclinati in posizione centrale	70
5.9	Impatti nel piano	74
<b>6</b>	<b>Reti Neurali</b>	<b>77</b>
6.1	Definizione Errori e Metriche	77
6.2	Reti Neurali Artificiali	78
6.2.1	Scelta degli Input e dei Target	80
6.3	Reti Neurali Convoluzionali	83
6.3.1	Scelta degli Input e dei Target	88
<b>7</b>	<b>Risultati</b>	<b>99</b>
7.1	Risultati per impatti in posizione centrali	99
7.1.1	Predizione della forza di impatto massima	99
7.1.2	Predizione dell'angolo $\phi$	101
7.1.3	Predizione dell'angolo $\theta$	102
7.2	Risultati per impatti sul piano	105
7.2.1	Predizione della forza di impatto	105
7.2.2	Predizione dell'angolo $\phi$	109
7.2.3	Predizione dell'angolo $\theta$	112
<b>8</b>	<b>Conclusioni</b>	<b>113</b>
	<b>Bibliografia</b>	<b>117</b>

# Capitolo 1

## Introduzione

Negli ultimi decenni, i materiali compositi hanno assunto un ruolo sempre più rilevante nell'ambito ingegneristico e strutturale, incluso il settore aerospaziale e aeronautico. Questa tendenza è supportata da diversi vantaggi, come: la bassa densità; le elevate proprietà strutturali, ad esempio la rigidità a parità di massa; la resistenza ai cicli a fatica; e la resistenza alla corrosione. Ciò rende particolarmente interessante nel settore aerospaziale l'utilizzo di tali materiali, in sostituzione di una parte delle componenti metalliche, in quanto, una riduzione di massa del velivolo è associata ad un minor consumo di carburante, con evidenti vantaggi economici e ambientali. Lo svantaggio principale dell'uso di materiali compositi è rappresentato dalla necessità di prevedere un opportuno programma di manutenzione, in quanto l'uso dei laminati compositi, comporta peculiari fenomeni di danneggiamento e rottura. Si possono sviluppare meccanismi di danneggiamento più complessi dei materiali metallici; una categoria importante, associata anche al settore aerospaziale, sono dovuti agli impatti a bassa velocità, o LVI (*low velocity impact*). Questi possono generare danni interni al materiale, non facilmente identificabili o BVID (*barely visible impact detection*). Durante la vita operativa di un aeromobile, tali danni possono derivare da diverse fonti, come detriti sulla pista, impatti con uccelli, grandine, o la caduta di attrezzi durante la normale manutenzione [49]. La presenza di danni nelle strutture difficili da identificare, comportano elevate costi di manutenzione, associati alle necessarie ispezioni periodiche e alla sostituzione delle parti. Nell'industria aeronautica, infatti, i costi di mantenimento sono il 20% del totale dei costi [10]. Pertanto, è necessario garantire che il risparmio in termini di carburante, associato alla minore massa del velivolo, non si traduca in un incremento delle spese di manutenzione. Per questa ragione, è essenziale implementare tecniche che consentano di ridur-

re il peso economico della manutenzione, identificando rapidamente solo le parti effettivamente danneggiate. Le tecniche di monitoraggio strutturale rientrano nel concetto di *Structural Health Monitoring* (SHM). Le tecniche SHM si basano principalmente sull'analisi dei segnali provenienti da sensori applicati alla struttura, con l'obiettivo di valutarne l'integrità. La scelta delle variabili misurate da tali sensori non è univoca; le misure tipicamente suggerite dagli articoli di ricerca includono la registrazione delle onde acustiche che si propagano all'interno della struttura, oppure la misurazione delle accelerazioni o degli spostamenti dei sensori. I dati raccolti possono essere elaborati o analizzati mediante una moltitudine di tecniche differenti. Tuttavia, grazie ai progressi tecnologici, sono stati introdotti approcci innovativi che fanno uso di algoritmi basati sul *machine learning* (ML). Vengono generalmente usati dati per addestrare tali algoritmi, provenienti da strutture simulate al calcolatore o da test sperimentali in strutture reali. Da queste informazioni gli algoritmi ML possono imparare a predire caratteristiche inerenti all'impatto, come la relativa posizione e l'energia o la forza associata, utili ad identificare le caratteristiche di un danno. I metodi basati sul machine learning possono risultare tuttavia molto costosi, poiché per implementare tali algoritmi sono necessari i dati di numerosi impatti. Ad esempio, il danneggiamento delle strutture durante una campagna di raccolta dati sperimentale può comportare un elevato costo economico, così come le risorse computazionali necessarie per elaborare le numerose simulazioni agli elementi finiti tramite modelli al calcolatore [54].

Nella corrente tesi è stato deciso di valutare l'efficacia delle reti neurali nella caratterizzazione degli impatti inclinati. La maggior parte dei lavori di ricerca, adottano tali tecniche per impatti perpendicolari, quindi risulta di interesse, verificare la validità anche nelle circostanze diverse da queste considerate. L'approccio adottato si basa sulla ricostruzione della forza di contatto massima, e sul verificare le capacità predittive sulla stima della direzione di impatto. Per fare ciò, si ripercorrono i lavori di tesi sviluppati da Cappellini [1] e Giacomini [2], riprendendone i modelli agli elementi finiti e indagando ulteriormente gli impatti non perpendicolari, in quanto avevano presentato precedentemente delle difficoltà nella caratterizzazione. I dati estratti dalle simulazioni vengono adoperati per l'addestramento di Reti Neurali Artificiali, comunemente usate in diverse pubblicazioni e Reti Neurali Convolutionali usate seguendo un approccio innovativo rispetto al loro uso tipico. Lo scopo finale è di confrontare i risultati ottenuti dalle due architetture e determinare se l'aumento della complessità, associato alle

reti neurali convoluzionali, garantisca prestazioni migliori. L'elaborato è diviso in due parti: la prima fornisce una panoramica sulle strutture composite, sui meccanismi di danneggiamento e sui criteri di rottura, nonché un'introduzione alle tecniche di machine learning e di monitoraggio strutturale. La seconda parte descrive le scelte e l'implementazione del modello FEM (*Finite Element Method*), le reti neurali adottate e i relativi risultati ottenuti.



## Capitolo 2

# Materiali Compositi

I materiali compositi sono un innovativo tipo di materiali che viene sempre più usato nell'ambiente ingegneristico. Questi, sono costituiti da due o più fasi chimicamente e fisicamente distinte che ne garantiscono proprietà superiori rispetto ai singoli materiali da cui è composto. Esistono diverse categorie di materiali compositi, essi sono costituiti da rinforzi immersi in una matrice, e in base al tipo di rinforzo si possono distinguere in: particellari, a fibre corte, fibre continue e laminati. Lo scopo delle fibre è di conferire rigidità al materiale, mentre la matrice ha lo scopo di proteggere le fibre dall'ambiente esterno e di mantenere le fibre in posizione e allineate nella direzione desiderata per prevenire il contatto e lo sfregamento delle fibre stesse.

La rapida crescita del settore aerospaziale, che si evidenzia negli ultimi decenni, richiede un uso di materiali con prestazioni strutturali sempre migliori, con maggiore resistenza alla corrosione e densità più ridotte. Per queste motivazioni i materiali compositi stanno trovando un maggiore impiego in questo settore. Essi infatti hanno minore densità rispetto alle leghe usate tradizionalmente, come quelle di alluminio. Ad esempio un materiale composito può avere una densità del 40% inferiore rispetto alle leghe di alluminio. L'utilizzo di materiali più leggeri garantirebbe agli aerei una massa inferiore, il che si traduce in un risparmio di carburante, quindi un risparmio economico, ma anche una riduzione del loro impatto da un punto di vista ambientale.

Il settore aeronautico ha fatto inconsciamente uso di materiali compositi nelle strutture fin dagli albori. Il legno, infatti, data la sua struttura anisotropa e sviluppata in fibre, può essere considerato come un materiale composito di origine naturale. Tale materiale venne usato a partire dal primo aereo dei fratelli Wright nel 1903 per le prime generazioni di aerei. Solo a partire dal 1927, grazie alle nuove

tecnologie di rivestimento e anodizzazione, le strutture di alluminio soppiantarono quelle in legno. Dopo quasi un secolo di supremazia delle leghe metalliche, questo trend è in controtendenza. I materiali compositi stanno tornando a rivestire un ruolo sempre maggiore in questo settore. Come si può osservare nei modelli di Boeing in Figura 2.1, i nuovi velivoli stanno facendo un crescente uso di materiali compositi a discapito delle leghe di alluminio [45]. Ad esempio, il Boeing 787 Dreamliner e l'Airbus A350 XWB sono costruiti con oltre il 50% di materiali compositi [49].

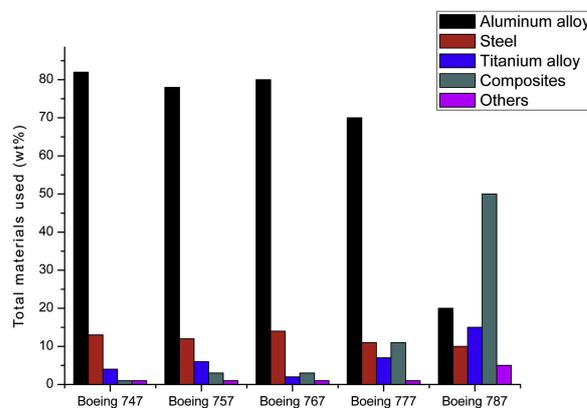


Figura 2.1: Materiali utilizzati nei modelli di Boeing [45].

L'uso crescente di materiali compositi nell'industria aerospaziale è dovuto principalmente alla loro maggiore resistenza specifica e alla migliore resistenza alla corrosione e alla fatica rispetto alla maggior parte dei metalli. Uno dei principali vantaggi è la riduzione della densità mantenendo elevate le proprietà meccaniche.

In questo elaborato verranno trattati esclusivamente i materiali compositi a matrice polimerica (PMC), pur esistendo altre varianti che non verranno analizzate, come i materiali compositi a matrice metallica (MMC) e quelli a matrice ceramica (CMC).

I materiali compositi a matrice polimerica offrono una resistenza specifica superiore, una migliore resistenza alla corrosione e alla fatica rispetto alle leghe di alluminio più comunemente utilizzate. Questi materiali trovano applicazione in strutture aerospaziali come flap, alettoni e porte del carrello di atterraggio. Tuttavia, i PMC presentano diversi svantaggi che ne limitano l'uso. I processi di produzione sono generalmente complessi e costosi, e la riparazione di questi materiali è difficile. Sono sensibili alle condizioni ambientali, in particolare ai raggi UV e all'umidità, che nel lungo periodo possono degradarne le caratteristiche meccaniche. Inoltre, la maggior parte dei materiali compositi non è riciclabile, ri-

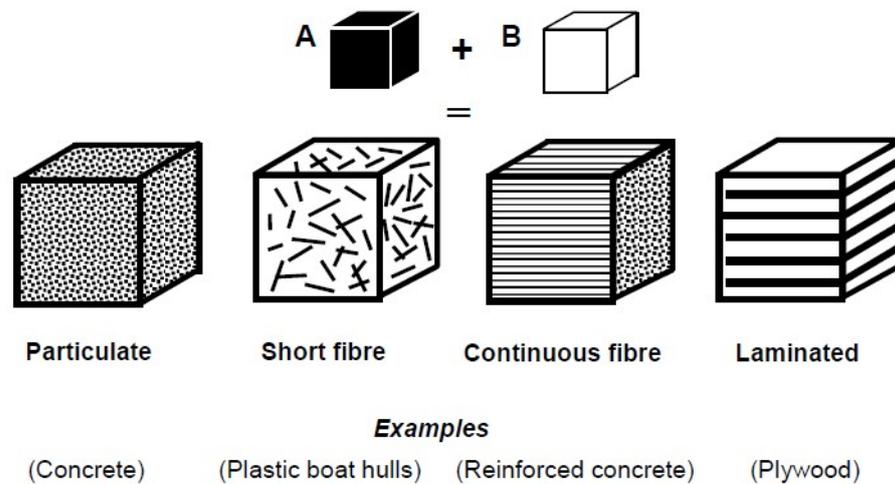


Figura 2.2: Differenti classi di materiali compositi [15].

chiedendo quindi un trattamento specifico per il fine vita. La conduttività termica ed elettrica dei compositi è inferiore rispetto ai materiali metallici, limitandone l'uso in alcune applicazioni.

Le proprietà dei materiali compositi possono variare in base al processo di produzione e alla qualità dei singoli componenti, rendendo essenziale un rigoroso controllo qualità. Processi di danneggiamento possono alterare significativamente le proprietà meccaniche della struttura; in particolare, la delaminazione può verificarsi in risposta a stress elevati o a eventi di impatto.

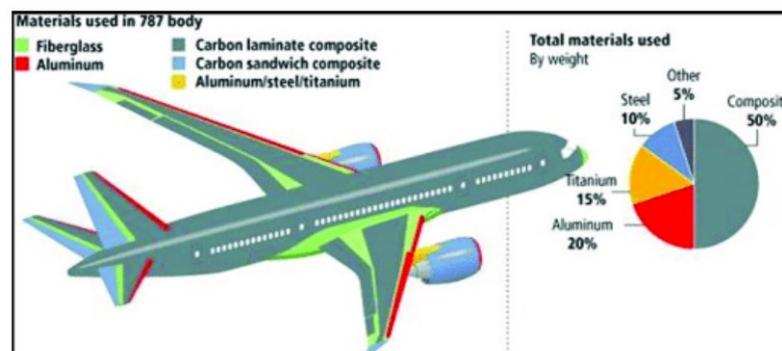


Figura 2.3: Differenti classi di materiali utilizzati in un Boeing 787 [47].

## 2.1 Proprietà

I PMC solitamente sono costituiti da fibre robuste, come vetro o carbonio, immerse in una matrice di plastica o resina epossidica, che fornisce protezione meccanica

e chimica. Le fibre possono essere continue o discontinue, ma possiedono una resistenza molto superiore rispetto agli stessi materiali in blocco. Ad esempio, le fibre di carbonio hanno una resistenza a trazione dell'ordine di 2400 MPa e un modulo di elasticità di 400000 MPa [40].

Una lamina di materiale composito rinforzato con fibre è anisotropo, cioè le sue proprietà dipendono dalla direzione delle fibre, due o più fogli vengono sovrapposti per formare un "lay-up" in modo che le direzioni delle fibre corrispondano a quelle dei carichi principali.

I primi materiali compositi sviluppati, noti come plastica rinforzata con vetro (GRP Glass-Reinforce Plastic), facevano uso di fibre di vetro con una matrice di resina epossidica. Venivano impiegati per produrre ad esempio radome e pale degli elicotteri Figura 2.4.

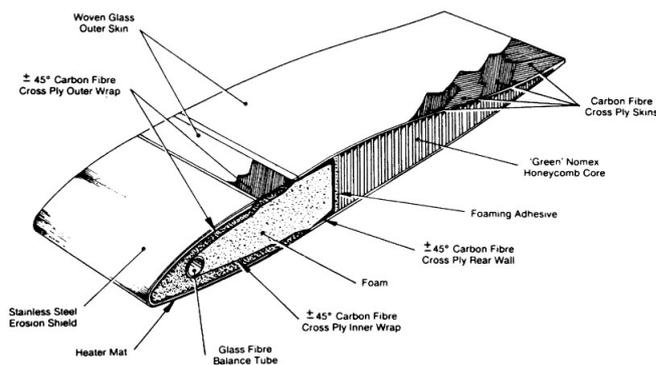


Figura 2.4: Sezione della pala principale del rotore dell'elicottero [40].

Dal 1960 sono state introdotte nuove fibre, come il Kevlar (a base di fibre di aramide), con caratteristiche di resistenza pari alle fibre di vetro, ma con maggiore rigidità. Successivamente sono state introdotte anche le fibre di carbonio, ottenendo i CFRP (Carbon Fiber Reinforced Plastic), che hanno proprietà simili a quelle di Kevlar, ma con maggiore rigidità, per cui ottime anche per l'uso strutturale. Tuttavia, i CFRP hanno alcuni svantaggi, essendo un materiale più rigido, risulta più fragile e suscettibile ai danni da impatto. Inoltre è sensibile all'umidità, con una conseguente riduzione delle prestazioni strutturali. In genere le sue proprietà meccaniche sono suscettibili a maggiori variazioni rispetto ai materiali d'uso comune, come i metalli. I CFRP vengono usati comunemente in diverse parti degli elicotteri e degli aerei garantendo un risparmio significativo del peso. Ad esempio il loro uso si può ritrovare in parti come fusoliera, ali e sezione di coda degli aeromobili. [40].

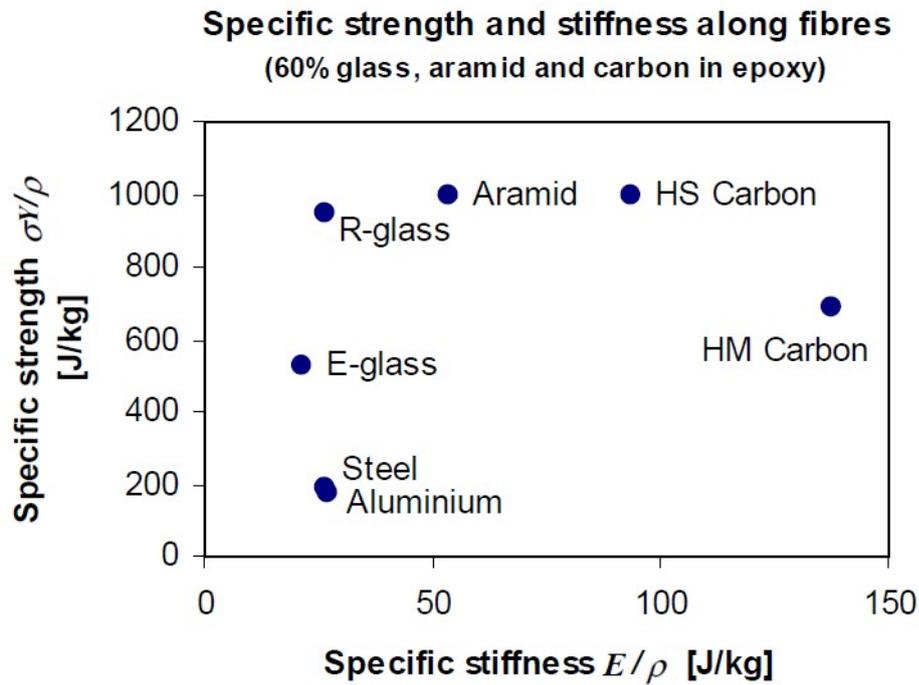


Figura 2.5: Differenti classi di materiali compositi confrontate con le proprietà dell'alluminio [15].

### 2.1.1 Proprietà meccaniche di una lamina

La legge di Hooke è una legge fisica che descrive il comportamento elastico dei materiali. Per un materiale isotropo, la legge di Hooke può essere espressa come:

$$\sigma = E\varepsilon \quad (2.1.1)$$

dove:

- $\sigma$  è la tensione,
- $E$  è il modulo di Young,
- $\varepsilon$  è la deformazione.

Per un materiale qualsiasi è possibile esprimere la legge di Hooke in termini triassiali (Eq. 2.1.2 e la relativa inversa Eq. 2.1.3).

$$\sigma = [Q]\varepsilon \quad (2.1.2)$$

$$\varepsilon = [S]\sigma \quad (2.1.3)$$

Dove al posto di tensione e deformazione monoassiale sono presenti i relativi vettori delle tensioni e delle deformazioni (Eq 2.1.4), il modulo di Young invece è sostituito dalla matrice di rigidezza [Q] (o *Stiffness matrix*). Mentre per la seconda equazione è evidenziata la matrice di *Compliance* [S] che è definita come l'inversa di [Q].

- Vettori delle deformazione e delle tensioni:

$$\epsilon = \begin{bmatrix} \epsilon_{11} \\ \epsilon_{22} \\ \epsilon_{33} \\ \gamma_{12} \\ \gamma_{23} \\ \gamma_{31} \end{bmatrix} \quad \sigma = \begin{bmatrix} \sigma_{11} \\ \sigma_{22} \\ \sigma_{33} \\ \tau_{12} \\ \tau_{23} \\ \tau_{31} \end{bmatrix} \quad (2.1.4)$$

- Matrice di compliance per materiali isotropi in condizioni di stress triassiali:

$$[S] = \begin{bmatrix} \frac{1}{E} & -\frac{\nu}{E} & -\frac{\nu}{E} & 0 & 0 & 0 \\ -\frac{\nu}{E} & \frac{1}{E} & -\frac{\nu}{E} & 0 & 0 & 0 \\ -\frac{\nu}{E} & -\frac{\nu}{E} & \frac{1}{E} & 0 & 0 & 0 \\ 0 & 0 & 0 & \frac{1}{G} & 0 & 0 \\ 0 & 0 & 0 & 0 & \frac{1}{G} & 0 \\ 0 & 0 & 0 & 0 & 0 & \frac{1}{G} \end{bmatrix} \quad (2.1.5)$$

Dove E (modulo di Young), G (modulo di taglio) e  $\nu$  (coefficiente di Poisson), legati alla equazione  $E = 2G(1 + \nu)$ .

Nel caso delle lamine di un composito è possibile definire la matrice di compliance per ogni singola lamina. Scegliendo opportunamente il sistema di riferimento, come quello in Figura 2.6 è possibile scrivere la matrice di compliance di ciascuna lamina (Eq. 2.1.6), considerando il comportamento ortotropico.

- Matrice di compliance per materiali ortotropi:

$$[S] = \begin{bmatrix} 1/E_1 & -\nu_{21}/E_2 & -\nu_{31}/E_3 & 0 & 0 & 0 \\ -\nu_{12}/E_1 & 1/E_2 & -\nu_{32}/E_3 & 0 & 0 & 0 \\ -\nu_{13}/E_1 & -\nu_{23}/E_2 & 1/E_3 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1/G_{12} & 0 & 0 \\ 0 & 0 & 0 & 0 & 1/G_{23} & 0 \\ 0 & 0 & 0 & 0 & 0 & 1/G_{31} \end{bmatrix} \quad (2.1.6)$$

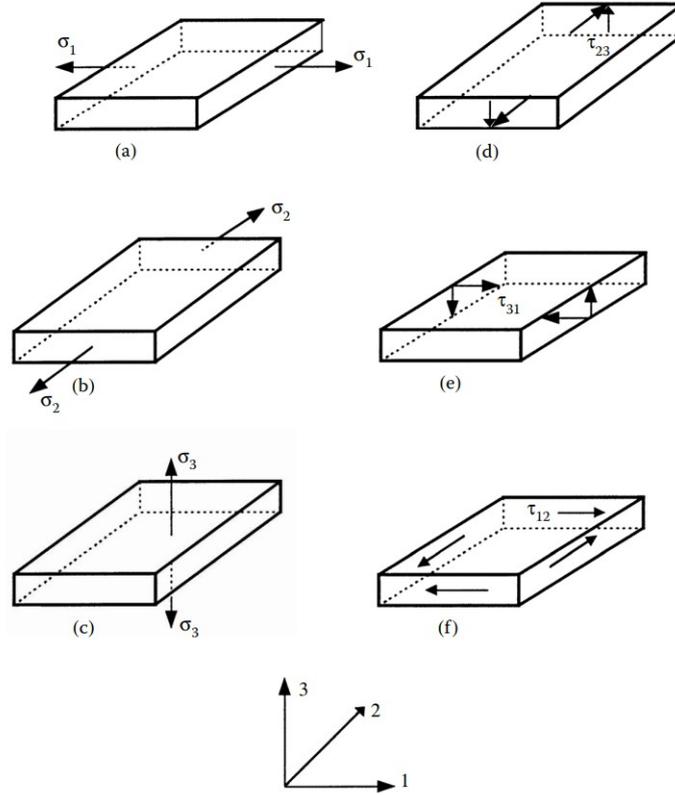


Figura 2.6: Assi principali della lamina [7].

Dove  $E_i$  sono i moduli di Young nelle direzioni principali,  $\nu_{ij}$  sono i coefficienti di Poisson, e  $G_{ij}$  sono i moduli di taglio. Questa matrice è simmetrica e contiene nove costanti elastiche indipendenti che definiscono il comportamento elastico del materiale con  $\nu_{ij} \neq \nu_{ji}$ .

$$\frac{\nu_{ij}}{E_{ii}} = \frac{\nu_{ji}}{E_{jj}} \quad (2.1.7)$$

È possibile semplificare ulteriormente queste equazioni considerando che i materiali compositi sono formati da lamine sottili. Di conseguenza gli effetti fuori dal piano sono trascurabili, per cui si può ridurre a caso di materiale ortotropico con stato di tensione planare, ossia  $\sigma_3 = \tau_{13} = \tau_{23} = 0$  e ottenere una versione semplificata dell'equazione (Eq. 2.1.8).

$$\begin{bmatrix} \epsilon_{11} \\ \epsilon_{22} \\ \gamma_{12} \end{bmatrix} = \begin{bmatrix} \frac{1}{E_{11}} & -\frac{\nu_{12}}{E_{11}} & 0 \\ -\frac{\nu_{12}}{E_{11}} & \frac{1}{E_{22}} & 0 \\ 0 & 0 & \frac{1}{G_{12}} \end{bmatrix} \begin{bmatrix} \sigma_{11} \\ \sigma_{22} \\ \tau_{12} \end{bmatrix} \quad (2.1.8)$$

Nei materiali compositi le lamine sono orientate ciascuna con un angolo  $\theta$

rispetto a una direzione globale, per cui è utile ricavare le equazioni per passare da sistema di coordinate locale a quello globale. Ciò è possibile effettuarlo attraverso qualche passaggio algebrico, a partire dall'equilibrio delle tensioni, come descritto in [?] si può identificare la matrice  $T$ , tale che:

$$\sigma_l = T\sigma \quad (2.1.9)$$

$$\varepsilon_l = RTR^{-1}\varepsilon \quad (2.1.10)$$

$T$  per cui, è una matrice di trasformazione necessaria per passare dal sistema di riferimento globale, a quello locale di ciascuna singola lamina identificato dal pedice  $l$ .

$$T = \begin{bmatrix} \cos(\theta)^2 & \sin(\theta)^2 & -2\sin(\theta)\cos(\theta) \\ \sin(\theta)^2 & \cos(\theta)^2 & -2\sin(\theta)\cos(\theta) \\ -\sin(\theta)\cos(\theta) & \sin(\theta)\cos(\theta) & \cos(\theta)^2 - \sin(\theta)^2 \end{bmatrix}, \quad (2.1.11)$$

$$R = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 2 \end{bmatrix} \quad (2.1.12)$$

La notazione  $T^{-1}$  è definita come  $T$  con  $-\theta$  che sostituisce l'angolo  $\theta$  in Eq. 2.1.11.  $T^{-T} = RTR^{-1}$  dove  $R$  è la matrice Reuter definita in Eq. 2.1.12.

$$\sigma = T^{-1}\sigma_l = T^{-1}Q\varepsilon_l = T^{-1}QT^{-T}\varepsilon = \bar{Q}\varepsilon \quad (2.1.13)$$

Si conclude che è possibile definire una equazione, analoga a quella di Hooke 2.1.2 per una singola lamina con orientazione diversa da quella scelta come principale.

Unendo più strati di laminato, ciascuno orientato nella opportuna direzione, si ottiene un materiale composito, la cui matrice di compliance è definibile mediante delle opportune trasformazioni in funzione dell'angolo fra la direzione 1 della lamina e un asse di riferimento globale, scelto univocamente per tutte le lamine del materiale composito.

## 2.2 Difetti caratteristici dei materiali compositi

Durante il processo di fabbricazione e la vita operativa i materiali compositi possono sviluppare diversi tipi di difetti. Tali difetti influenzano le prestazioni dei materiali compositi, con il rischio di compromettere la loro integrità strutturale. I principali tipi di difetti che possono verificarsi sono:

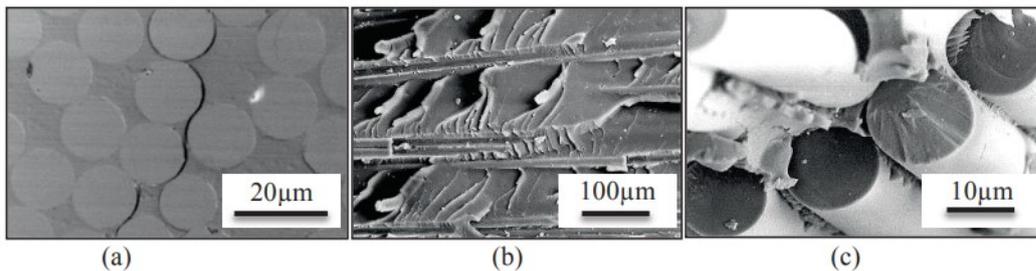
- Porosità: esse comprendono bolle d'aria e vuoti nel materiale.
- Danni alle fibre: comprendono fibre tagliate e danneggiate.
- Inclusioni: sono presenti corpi estranei incorporati nel materiale.
- Delaminazione: il distacco o la separazione di uno o più strati in un materiale composito, spesso a seguito di impatti o forze elevate.
- Fratture interlaminari: fratture tra gli strati del composito laminato. Si sviluppano attraverso lo spessore dei materiali compositi. Possono essere causate da altri difetti o da danni.
- Cracking da impatto: cricche causate da impatti.
- Deformazioni termiche: deformazioni dovute a variazioni di temperatura.
- Corrosione: corrosione sulle superfici del composito.
- Usura superficiale: comprendono i fenomeni di abrasione e danno superficiale.

Per garantire l'affidabilità e la durata di questi materiali, è essenziale monitorare e gestire i difetti sia durante la produzione che durante la vita operativa. Ciò può richiedere numerose ispezioni, manutenzioni e, nel caso, riparazioni. In ambienti ad alte prestazioni, come il settore aerospaziale, la gestione dei difetti è critica, poiché si traduce in un aumento dei costi e dei tempi di ispezione, rischiando di limitare l'utilizzo di questi materiali.

## 2.3 Tipi di danno

Nei materiali compositi, i processi di danneggiamento si manifestano attraverso dinamiche più complesse rispetto a quelle osservate nei materiali convenzionalmente impiegati nel settore aeronautico, come ad esempio quelli metallici. Tale

complessità è legata alla natura eterogenea e anisotropa di questi materiali compositi. In particolare, il danneggiamento può verificarsi a causa di una serie di fattori [44] [49], quali: condizioni ambientali come la temperatura, la presenza di umidità o l'esposizione ad agenti chimici. Altri fattori critici comprendono i diversi tipi di carico applicato al materiale, come cicli a fatica, fenomeni di impatto e carichi particolarmente intensi (specialmente di compressione e di taglio), e l'eventuale presenza di imperfezioni strutturali o difetti di fabbricazione.



**Figura 2.7:** Esempi mediante microscopio SEM di: (a) cedimento interlaminare; b) cedimento intralaminare; (c) cedimento translaminare [44].

Nello specifico dei materiali compositi, il danno si può classificare in quattro principali categorie (Fig. 2.7), che si possono distinguere a loro volta in intralaminari, interlaminari e translaminari (Figura 2.8), queste vengono distinte in funzione dall'elemento del materiale composito coinvolto. In particolare:

- Rottura della matrice: è un fenomeno intralaminare, infatti coinvolge la matrice del materiale da cui sono composte le singole lamine. Questo danneggiamento incorre quando il carico applicato al materiale supera quello di rottura della matrice.
- Rottura delle fibre: è di tipo intralaminare, ma in alcuni casi viene definito come translaminare, infatti coinvolge le fibre che costituiscono le lamine. Esso avviene quando il carico applicato al materiale supera quello di rottura delle fibre.
- Rottura dell'interfaccia fra fibre e matrice: è considerato intralaminare se si sviluppa all'interno della lamina, mentre interlaminare se si verifica nell'interfaccia tra due lamine. Questo tipo di danno è legato alle proprietà adesive della matrice.
- Delaminazione: può instaurarsi in presenza di cricche. È un danno di tipo interlaminare. Si sviluppa a causa di forze di taglio generate da concentrazioni di tensioni che portano alla separazione dei layup.

## 2.4 Meccanismi di cedimento

Per comprendere al meglio i tipi di danno e i meccanismi di cedimento dei materiali compositi, è necessario fare riferimento ai modi di rottura, noti anche come modalità di rottura. Questi sono i criteri base, utilizzati per descrivere i diversi tipi di meccanismi del fallimento strutturale. Possono presentarsi singolarmente o in combinazione, a seconda delle forze applicate e delle proprietà del materiale. Sono classificati in tre tipi principali:

- Modalità I (apertura): Questa modalità, conosciuta come *opening mode* in inglese, si verifica quando le forze applicate tendono a separare le due superfici di una frattura.
- Modalità II (taglio): Questa modalità, chiamata *shear mode* in inglese, si verifica quando le forze applicate causano uno scorrimento lungo il piano della frattura.
- Modalità III (lacerazione): Questa modalità, conosciuta come *tearing mode* in inglese, si verifica quando le forze applicate causano uno scorrimento perpendicolare al piano della frattura.

Un materiale composito può essere soggetto a vari tipi di danni, questi dipendono da fattori quali, il carico applicato, la struttura delle lamine, le proprietà strutturali dei materiali utilizzati e la geometria del materiale. Questi danni possono essere classificati in cinque categorie: nel piano, fuori dal piano, interlaminare, intralaminare e translaminare [49]. Le ultime tre tipologie citate (rappresentate in figura 2.8), vengono considerate come cedimenti basati sulla frattura: infatti, si può definire il cedimento translaminare come quello che coinvolge le fibre del materiale composito a causa di fenomeni di trazione e compressione. Il danneggiamento delle aree di interfaccia fra le lamine, rientra invece nel danneggiamento interlaminare. Infine, abbiamo il fallimento intralaminare, che si verifica nello spessore della lamina. Le modalità di fallimento sono strettamente legate al tipo di carico applicato. Ad esempio, i fenomeni di rottura associati a carichi nel piano sono diversi da quelli fuori dal piano. Questi ultimi, in particolare, includono danni da flessione, ma soprattutto da impatto.

Nonostante il processo di danneggiamento sia influenzato da numerosi fattori come il layup del laminato, il tipo di carico applicato e la geometria. In tutti i casi il processo di danneggiamento ha inizio da quello che richiede l'energia minore. Solitamente, ciò si verifica in presenza di difetti, nella matrice o nell'interfaccia

fra fibre e matrice. Il danno poi prosegue con i danneggiamenti che richiedono energie superiori, fino a raggiungere la rottura delle fibre, che richiedendo un livello di energia più significativo.

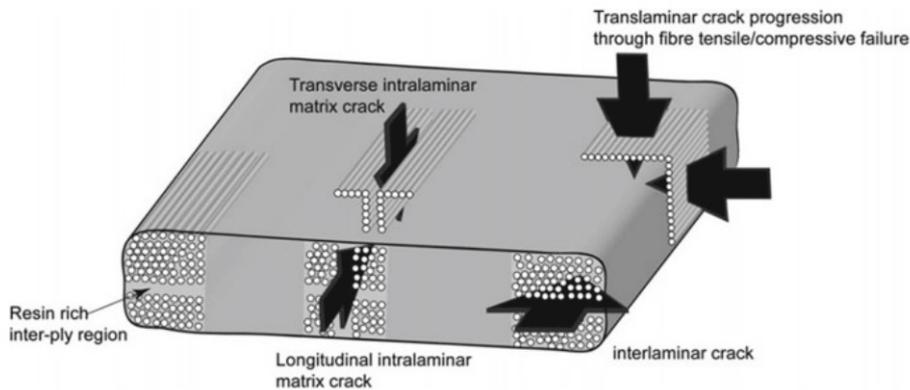


Figura 2.8: Panoramica sulle modalità di rottura [49].

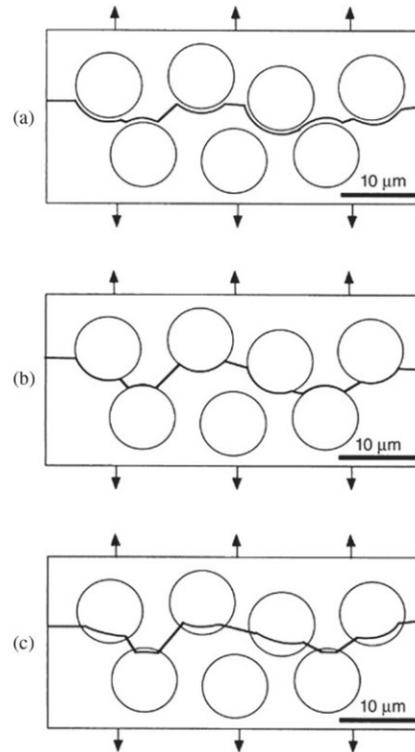
A differenza dei materiali metallici, gli impatti a bassa velocità nei materiali compositi risultano particolarmente dannosi. Questi non lasciano segni facilmente visibili, ma causano danni interni al laminato, portando al fenomeno della delaminazione. Questo processo si sviluppa a causa di un'elevata sollecitazione del materiale fuori dal piano, che danneggia le aree di interfaccia delle lamine adiacenti e porta alla loro separazione. La delaminazione risulta come una combinazione di più modalità di rottura, come l'apertura o *opening* (modalità I), il taglio o *shear mode* (modalità II) e la lacerazione o *tearing* (modalità III). Questo processo può essere favorito da una diversa rigidità tra i layup del laminato, difetti o impatti. Inizia con un piccolo danno, come una crepa in un singolo strato, che viene interrotta dalle lamine adiacenti e prosegue nelle aree di interfaccia, separando le lamine.

I materiali compositi spesso non falliscono una volta superato il limite di rottura. Tuttavia, possono perdere integrità e la rottura completa avviene in diverse fasi. Ad esempio, uno strato potrebbe fallire per primo, e gli altri potrebbero resistere a carichi crescenti fino alla completa rottura del laminato.

### 2.4.1 Rottura per trazione

Il cedimento a trazione segue la dinamica nota come meccanismo di Cook-Gordon. Il primo danno ha luogo a partire da un difetto interno a una fibra, da questa si propaga attraverso la matrice verso le fibre adiacenti. In base alla forza di adesione dell'interfaccia fra fibre e matrice, si possono distinguere: un distacco

delle fibre in una zona limitata e liscia per un grado di adesione basso; mentre nel caso di un elevato grado di adesione, la rottura si propaga su una superficie più ampia e frastagliata [49].



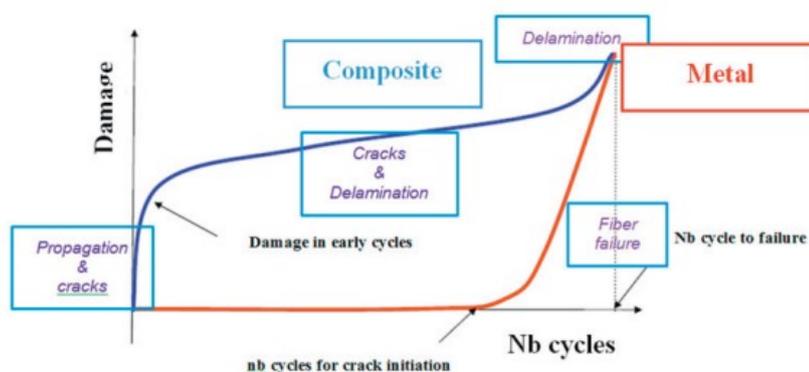
**Figura 2.9:** Illustrazione di micromeccanismi di separazione degli strati in un laminato. a) rottura coesiva nella matrice, b) rottura dell'interfaccia fibra-matrice, c) rottura trans laminare [49].

### 2.4.2 Rottura per compressione

I materiali compositi risultano meno resistenti in compressione che in trazione, in quanto, durante carichi di compressione, dopo un primo danneggiamento della matrice, il materiale perde rigidità provocando fenomeni di buckling nelle fibre, portando infine le fibre a frammentarsi [44]. Per questo motivo il cedimento a compressione, è dominato da bande causate da fenomeni di micro buckling delle fibre, noti come *kink-bands*, che si sviluppano all'interfaccia fibre-matrice. Le fibre al microscopio risultano infatti rugose, e non lisce [49]. Il cedimento a compressione avviene quasi immediatamente, infatti, i materiali compositi risultano generalmente meno adatti a questo genere di carichi.

### 2.4.3 Rottura a fatica

I materiali compositi hanno ottime caratteristiche di resistenza a fatica, tuttavia, avendo una dinamica di cedimento diversa rispetto ai materiali metallici, le formule convenzionalmente usate nel calcolo della durata a fatica non sono totalmente applicabili per questo nuovo genere di materiali. Nel lavoro di [44] si è cercato di delineare i passaggi chiave che porta un materiale composito a danneggiarsi in seguito a cicli di compressione/tensione.



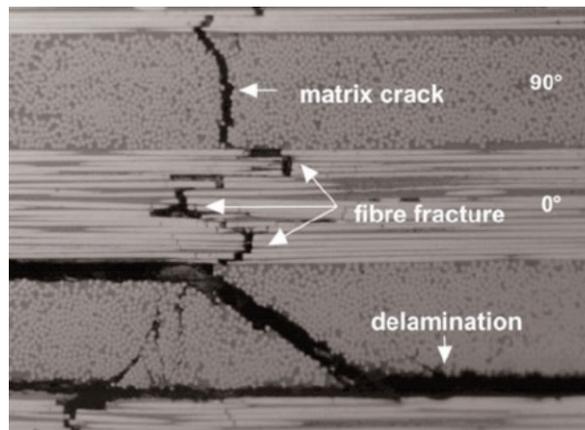
**Figura 2.10:** Comparazione del danno cumulativo a seguito di cicli a fatica in un materiale composito rispetto a un materiale metallico [44].

Il danneggiamento ha inizio nelle regioni a resistenza inferiore, nelle zone in cui le lamine non presentano fibre allineate con il carico, si formano cricche intralaminari, quando il limite di rottura della matrice viene superato. Tuttavia, questo tipo di microdanneggiamenti ha un impatto minimo sulla resistenza finale del materiale [44]. Come si può osservare dalla curva in Figura 2.10, nonostante ci siano aree danneggiate, il materiale composito può resistere ancora a lungo prima che si sviluppi un danno da delaminazione che porti anche le fibre allineate con il carico a cedere dando origine a un danno translaminare.

### 2.4.4 Rottura da impatto

La gravità del danneggiamento di un materiale composito è legato all'energia di impatto [49] e alla sua velocità. In base alla velocità si possono distinguere due casistiche, quelle a bassa velocità o *Low Velocity Impact* (LVI), e ad alta velocità *High Velocity Impact* (HVI). Gli impatti LVI, risultano particolarmente gravosi, questi infatti generano danni di tipo *Barely Visible Impact Damage* (BVID), ossia danneggiamenti che, nonostante siano gravosi dal punto di vista strutturale, non sono facilmente identificabili ad occhio nudo. Fra i materiali compositi, risultano

particolarmente associati a questo genere di danno, quelli con fibre rigide e poco duttili, come i laminati in fibra di carbonio e resina epossidica. Ciò è legato al loro comportamento elasto-plastico limitato, durante l'impatto, non riescono ad assorbire l'energia dell'urto mediante una deformazione plastica, e si danneggiano portando alla delaminazione e la rottura delle fibre [49]. L'inizio del fenomeno di danneggiamento ha luogo all'interno della matrice, in presenza di uno stress residuo della lavorazione, o di un altro genere di difetto. Negli impatti LVI più energetici, il danno è dominato da fenomeni di rottura di taglio (modo II), portando alla separazione fra fibre e matrice in una lamina. L'insieme di queste fratture converge nella separazione della lamina, generando la delaminazione. In Figura 2.11 è presente un danneggiamento fra più lamine a causa di un impatto LVI.



**Figura 2.11:** Tipi di cedimento in un composito a causa di un urto a bassa velocità [49].

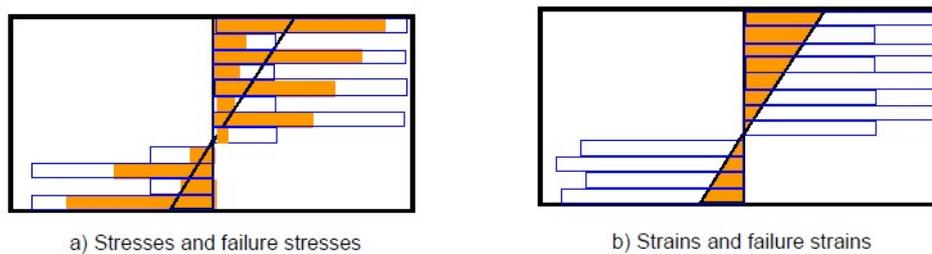
La delaminazione avviene nelle interfacce dove le fibre hanno orientamenti differenti, a causa delle forze di taglio interlaminari, che vengono accentuate dalle cricche nella matrice e dalla diversa rigidità tra le lamine. Durante l'impatto, nei laminati sottili, si può verificare una grande delaminazione nelle lamine inferiori del laminato, in direzione opposta all'impatto, insieme a cricche nella matrice dovute a fenomeni di tensione, dovuto alla flessione del laminato. Nella superficie anteriore, quella in cui si verifica l'impatto, si può osservare un danneggiamento locale a causa della compressione e tagli, direttamente associati alla compressione causata dall'urto. Al contrario, sulla superficie posteriore del laminato può essere presente un cedimento a trazione.

L'area di delaminazione peggiore, risulta nel piano intermedio del laminato, in quanto è l'area maggiormente soggetta alle sollecitazioni di taglio (modo II). Causando una rilevante perdita di rigidità flessionale.

A differenza degli impatti LVI, in cui domina il danneggiamento a causa del modo II, gli impatti ad alta velocità o *High Velocity Impact* (HVI), dominano gli effetti delle onde di stress, inducendo la delaminazione tra le lamine attraverso il modo I. Si riscontra prevalentemente nei materiali compositi a fibra polimerica (ad esempio Dyneema HB26), in cui la delaminazione di modo II si verifica più vicina al sito di impatto e al piano intermedio del laminato, mentre lontano dal sito di impatto, la componente di modo I aumenta [49].

## 2.5 Criteri di Failure

Nei materiali isotropi si usano criteri di *failure* spesso basati sulle tensioni. Questi infatti, tensioni e deformazioni seguono andamenti analoghi. Nei materiali compositi, a causa delle loro caratteristiche anisotrope, le deformazioni hanno un andamento diverso rispetto alle tensioni. Ciò dipende dal layup del materiale, e dalla direzioni delle tensioni come si evince da figura 2.12: infatti l'andamento delle deformazioni a seguito, ad esempio di un carico flessionale, genera un andamento lineare delle deformazioni, ma non altrettanto lineare delle tensioni. Per cui risulta difficile un approccio in cui si riesce a definire un criterio di failure basato solo sulle tensioni. Importante notare che i criteri di failure in questi materiali vengono valutati nei sistemi di riferimento locali, ossia secondo gli assi principali che identificano il composito.



**Figura 2.12:** Differenza tra (a) tensioni di failure e (b) deformazioni di failure in un materiale composito sottoposto a un carico di tipo flessionale [15].

### 2.5.1 Criterio di Failure della lamina

Viene comunemente usato il criterio di failure sulla massima deformazione e massima tensione ammissibile. Secondo questo criterio, si verifica il danno se si verifica una delle 2 condizioni presenti. Nella figura 2.13 rappresenta le equazioni che identificano questo criterio.

$$\begin{array}{cc}
\text{Maximum strain :} & \text{Maximum stress :} \\
\text{Failure when} \left\{ \begin{array}{l} \varepsilon_1 < \varepsilon_{1uc} \text{ or } \varepsilon_1 > \varepsilon_{1ut} \\ \varepsilon_2 < \varepsilon_{2uc} \text{ or } \varepsilon_2 > \varepsilon_{2ut} \\ |\gamma_{12}| > \gamma_{12u} \end{array} \right. & \left\{ \begin{array}{l} \sigma_1 < \sigma_{1uc} \text{ or } \sigma_1 > \sigma_{1ut} \\ \sigma_2 < \sigma_{2uc} \text{ or } \sigma_2 > \sigma_{2ut} \\ |\tau_{12}| > \tau_{12u} \end{array} \right.
\end{array}$$

**Figura 2.13:** criterio di failure della minima deformazione e massima tensione [15].

Dove  $\varepsilon_i$  e  $\sigma_i$  sono le rispettive deformazioni e tensioni lungo gli assi principali.  $\gamma_{12}$  e  $\tau_{12}$  sono le relative deformazioni e tensioni di taglio.  $\varepsilon_{iuc}$  e  $\varepsilon_{iut}$  sono le deformazioni di failure rispettivamente in compressione e tensione.  $\sigma_{iuc}$  e  $\sigma_{iut}$  le relative tensioni di failure.  $\gamma_{12u}$  e  $\tau_{12u}$  sono le relative deformazioni e tensioni di taglio di failure. Questo metodo non tiene conto delle differenze tra le tensioni fra una lamina e l'altra e ciò può comportare lo sviluppo di failure discontinui.

### 2.5.2 Criterio di Failure Tsai-Hill

Il criterio di Tsai-Hill è una estensione del criterio di Von Mises ma con lo scopo di identificare il failure delle lamine in un materiale composito. Una lamina si considera danneggiata se la seguente equazione risulta verificata:

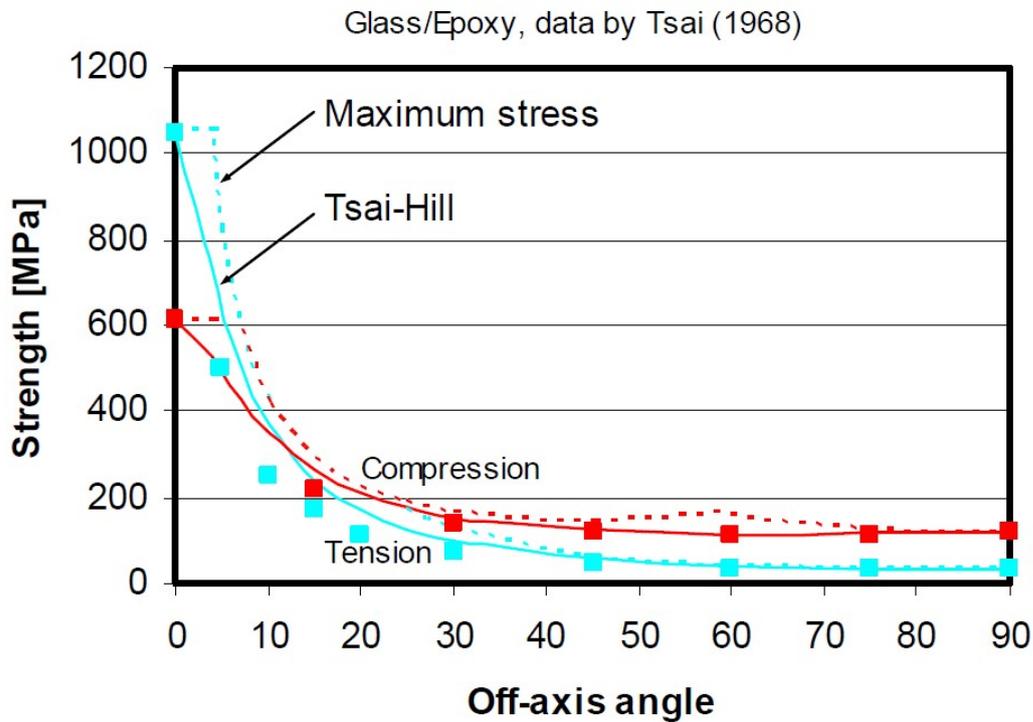
$$\frac{\sigma_1^2}{\sigma_{1u,T}^2} - \frac{\sigma_1\sigma_2}{\sigma_{1u,T}^2} + \frac{\sigma_2^2}{\sigma_{2u,T}^2} + \frac{\tau_{12}^2}{\tau_{12u}^2} < 1 \quad (2.5.1)$$

Dove:  $\sigma_{1u,T}$ ,  $\sigma_{2u,T}$  e  $\tau_{12u}$  sono rispettivamente le tensioni di rotture delle lamine del materiale composito lungo gli assi principali 1, 2 in trazione, e lo sforzo di taglio di rottura.

Nella figura 2.14, il criterio di Tsai-Hill è più adatto di quello di massima tensione nel rappresentare le situazioni reale. Questo criterio, tuttavia non è applicabile in tutti i casi, risulta efficace solo in determinate condizioni di carico. Inoltre non riesce a distinguere il tipo di danno, ad esempio la rottura delle fibre o della matrice.

### 2.5.3 Criterio di Failure Tsai-Wu

Il criterio di Tsai-Wu a a differenza del criterio di Tsai-Hill distingue gli effetti di compressione da quelli di trazione. Una lamina si considera danneggiata se la seguente equazione risulta verificata:



**Figura 2.14:** criterio di failure della minima deformazione e massima tensione a confronto con Tsai-Hill e i dati sperimentali [15].

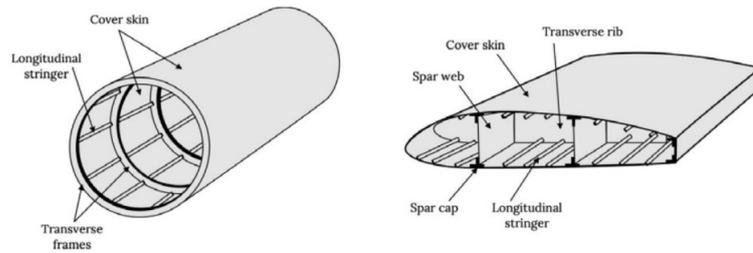
$$H_1\sigma_1 + H_2\sigma_2 + H_6\tau_{12} + H_{11}\sigma_1^2 + H_{22}\sigma_2^2 + H_{66}\tau_{12}^2 + 2H_{12}\sigma_1\sigma_2 < 1 \quad (2.5.2)$$

Dove:  $H_1, H_2, H_6, H_{11}, H_{22}, H_{66}$  e  $H_{12}$  Sono dei termini correttivi che vengono valutati sperimentalmente o attraverso leggi empiriche, e sono legati alle tensioni ultime della lamina.

## 2.6 Pannelli irrigiditi

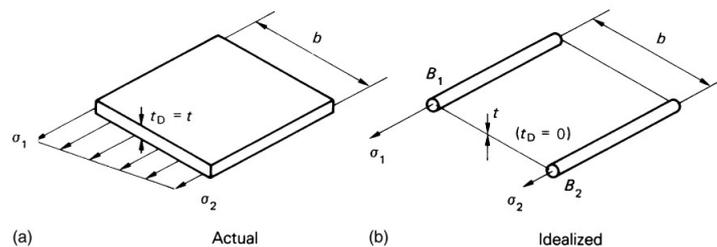
In ambiente aerospaziale si fa ampio uso di materiali e strutture leggere, per ridurre la massa dei velivoli, e di conseguenza il carburante necessario. I pannelli irrigiditi, sono una scelta perfetta per ottenere questo risultato. Sono elementi strutturali che contengono rinforzi per aumentare la loro rigidità. Un pannello irrigidito è composto da un pannello e da degli irrigidimenti usati come strutture di supporto. Questa configurazione è usata comunemente in diverse strutture aeronautiche come fusoliera, ali e superfici di coda, ma anche parti strutturali di veicoli spaziali, veicoli terrestri, e in molte altre applicazioni in cui la leggerez-

za e la resistenza sono di fondamentale importanza. I pannelli irrigiditi, grazie alla loro peculiare conformazione incrementano resistenza e rigidità di una struttura, distribuendo il carico in modo più efficiente e riducendo la possibilità di deformazioni indesiderate.



**Figura 2.15:** Esempi di strutture con pannelli irrigiditi [50].

Per strutture di questo tipo è possibile idealizzarle, semplificando la trattazione matematica. Infatti i longheroni e le flange del longherone hanno sezioni trasversali ridotte rispetto alla sezione completa, per cui le variazioni di tensioni al loro interno è limitata. Per questo motivo in questa trattazione si considerano che gli irrigidimenti devono sopportare solo gli sforzi assiali, e questi sono costanti in ciascun irrigidimenti [40]. Per questo motivo è possibile sostituire gli irrigidimenti con delle aree in cui l'area è concentrata chiamati *booms*. Al contrario il rivestimento o *skin* supporta solo gli sforzi tangenziali e dato che gli spessori sono ridotti, viene usata l'ipotesi che la tensione di taglio sia costante lungo la sezione del pannello. L'idealizzazione (Figura 2.16) porta a considerare lo spessore dello *skin* nullo e sommare il suo contributo nell'area dei *booms*.



**Figura 2.16:** idealizzazione di un pannello [40].

Lo spessore  $t_d$  è quello considerato della *skin*, nel caso reale è pari allo spessore della lamina  $t$ , mentre in quello idealizzato corrisponde a 0.

Se si suppone che la distribuzione della tensione normale nel pannello reale vari linearmente da due valori incogniti  $\sigma_1$  e  $\sigma_2$ .

$$\sigma_2 t_D \frac{b^2}{2} + \frac{1}{2}(\sigma_1 - \sigma_2) t_D b \frac{2}{3} b = \sigma_1 B_1 b \quad (2.6.1)$$

È possibile calcolare l'area dei *booms*  $B_1$  e  $B_2$  considerando l'equilibrio dei momenti, mediante l'equazione 2.6.1. E si ottengono le relative equazioni 2.6.2 e 2.6.3.

$$B_1 = \frac{t_D b}{6} \left( 2 + \frac{\sigma_2}{\sigma_1} \right) \quad (2.6.2)$$

$$B_2 = \frac{t_D b}{6} \left( 2 + \frac{\sigma_1}{\sigma_2} \right) \quad (2.6.3)$$

## Capitolo 3

# Machine Learning

Il *machine learning* (ML) è un sottoinsieme dell'intelligenza artificiale (AI) che si occupa di creare sistemi che apprendano o migliorino le performance in base a dei dati in input [27]. A differenza di altri metodi informatici, questi sistemi non necessitano una programmazione diretta, infatti spesso questo genere di algoritmi vengono usati quando non sono note le relazioni tra input e output. L'implementazione di questi metodi avviene attraverso un processo di addestramento, il cui scopo è quello di insegnare attraverso degli esempi, associando una serie di input a dei target, in modo tale che il sistema di ML possa apprendere la relazione presente [62]. Questo strumento risulta estremamente efficace in quanto un buon algoritmo di ML può riconoscere pattern anche complessi rendendolo adatto ad applicazioni ad ampio spettro. Merito anche l'aumento della potenza di calcolo dei sistemi informatici, negli ultimi anni c'è stata una impennata nelle loro capacità e nel loro sviluppo in tutti i settori. Algoritmi di ML possono riconoscere caratteristiche complesse in immagini, utile per il riconoscimento facciale, la classificazione di testi o la diagnosi medica. Inoltre è possibile creare modelli di regressione, in modo da prevedere attraverso un andamento continuo i valori in output. Proprio per questo motivo sono adatti ad analizzare grandi quantità di dati e informazioni, individuando tendenze, relazioni nascoste e comportamenti imprevisti. Rendendoli adatti a predire il comportamento strutturale in ingegneria, ma anche la domanda di prodotti in ambito commerciale, il traffico stradale o i prezzi delle azioni in ambito economico. Il ML può automatizzare processi complessi, riducendo la necessità di intervento umano. Ad esempio, nell'automazione dei processi aziendali o nella guida autonoma.

### 3.1 Tipologie di Machine Learning

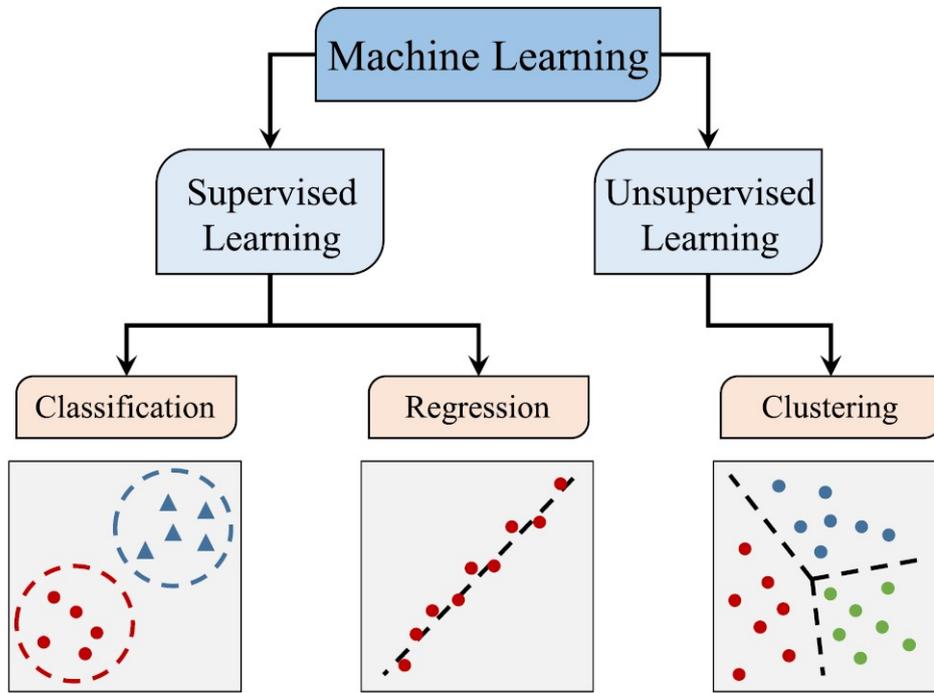


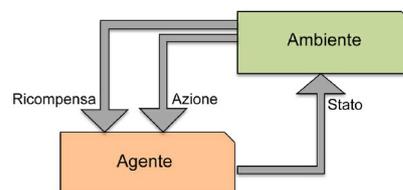
Figura 3.1: Divisione e sottodivisione degli algoritmi di Machine Learning [6].

Il machine learning si divide in funzione al suo scopo e la presenza o meno di caratteristiche note. In particolare si può distinguere (Fig. 3.1):

- **Machine Learning Supervised (Supervisionato):** Ha lo scopo di classificare con fini predittivi. È addestrato utilizzando dati di input, detti anche caratteristiche, e dati di output noti, ossia con etichette e target. L'obiettivo è quello della rete durante l'addestramento è riconoscere il nesso che c'è fra i dati in input e quelli in output. In modo tale che il modello possa fare previsioni o classificazioni di nuovi dati. Alcuni esempi sono gli algoritmi quali, *Reti Neurali Artificiali (ANN)*, *Reti Neurali Convolutionali (CNN)*, *Support Vector Machine (SVM)*, *Regressione Lineare*, *Random Forest*.
- **Machine Learning Unsupervised (Non Supervisionato):** L'obiettivo è di scoprire relazioni nei dati nascoste, in modo tale da raggruppare opportunamente i dati. Questa categoria di machine learning cerca di trovare modelli o strutture nei dati senza utilizzare etichette o target noti. Infatti è il modello che cerca autonomamente di identificare pattern o

strutture nei dati. Alcuni esempi di utilizzo sono il *clustering*, la *riduzione delle dimensionalità*, l'*analisi delle componenti principali* (PCA), e l'*analisi di associazione*.

- **Reinforcement Learning (RL)** : si tratta di un nuovo tipo di Machine Learning è un modello di apprendimento automatico in cui un agente interagisce con un ambiente e apprende a compiere azioni ottimali per massimizzare una ricompensa cumulativa [17]. In Figura 3.2 è schematizzato il funzionamento di questo tipo di ML. L'**agente** è l'entità principale in questo processo, responsabile per l'apprendimento e la presa di decisioni in base alle informazioni ricevute dall'**ambiente**. L'**ambiente** è il contesto in cui l'agente opera, esso interagisce direttamente con l'agente, ricevendo feedback in risposta alle sue **azioni**. Le **azioni** comprendono tutte le scelte a disposizione dell'agente per interagire con l'ambiente. Lo **stato** è la descrizione del contesto corrente dell'ambiente, fornendo all'agente informazioni sulla posizione e attuale corrente. La **ricompensa** è un segnale numerico che l'agente riceve in risposta alle azioni intraprese. Lo scopo dell'agente diventa quello di massimizzare la ricompensa cumulativa nel corso del tempo, di conseguenza contribuendo al processo di apprendimento. L'obiettivo di RL è far sì che l'agente apprenda una strategia o ottimale per massimizzare la ricompensa cumulativa nel corso del tempo. Algoritmi di questo tipo includono Algoritmi Genetici, *Q-Learning*, *Deep Q-Networks* (DQN), *Policy Gradients*, ecc. Questo genere di modello viene utilizzato in diversi ambiti, tra cui robotica, finanza, giochi, healthcare e molto altro.



**Figura 3.2:** Schema che rappresenta il Reinforcement Learning [17].

Oltre alle caratteristiche strutturali che dividono questi approcci, anche la valutazione dei risultati differiscono. Ad esempio con gli algoritmi supervisionati è possibile definire una valutazione oggettiva basata sugli errori e scarti, mentre per quelli non supervisionati non è possibile, infatti si effettua una valutazione più soggettiva e che dipende dai casi studiati. Ad esempio, nel *clustering*, si può valutare la coesione e la separazione dei cluster.

### 3.1.1 Panoramica degli algoritmi di Machine Learning

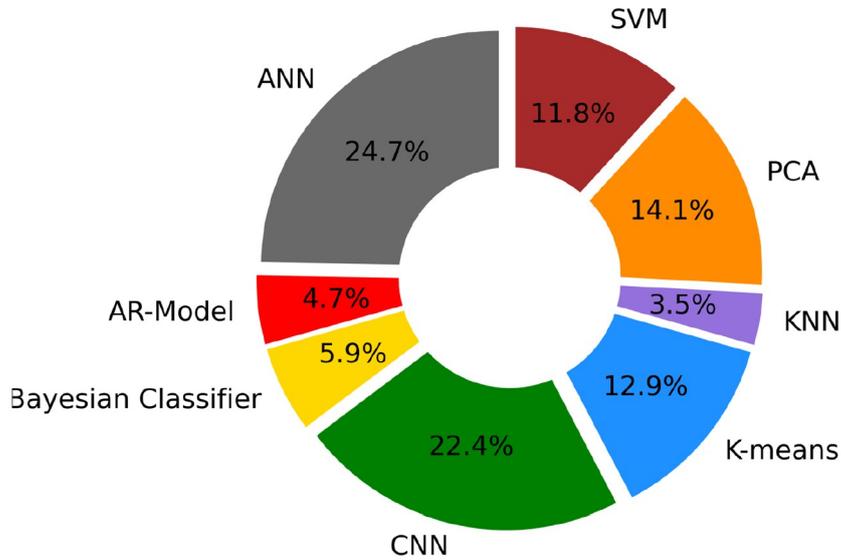
Negli anni sono stati sviluppati diversi algoritmi di machine learning, ciascuno con determinate caratteristiche, vantaggi e svantaggi. Ciascuno si avvicina ai dati in modo differente, e non esistono reali indicazioni per distinguere un modello migliore di un altro, infatti dipende dall'applicazione specifica, il tipo di dati disponibili, e gli obiettivi. Alcuni dei principali algoritmi utilizzati in ambito ingegneristico/strutturale sono [6]:

- **Reti Neurali Artificiali (ANN)**: mimano il comportamento del cervello umano. Formati da elementi chiamati neuroni, disposti in diversi layer.
- **Convolutional Neural Network (CNN)**: mimano le caratteristiche dell'elaborazione delle immagini del cervello umano. Nascono per l'elaborazione e classificazione di immagini, risultano particolarmente efficaci a riconoscere caratteristiche anche complesse. Possono essere usate anche per il trattamento di dati multidimensionali o segnali audio.
- **Algoritmi Genetici**: Questi algoritmi si ispirano al processo evolutivo e vengono utilizzati per l'ottimizzazione delle reti neurali.
- **Support Vector Machine (SVM)**: Si basano sulla ricerca di un iperpiano ottimale che separi le classi nei dati. utilizzate per la classificazione e la regressione.
- **Alberi di Decisione**: gli alberi di decisione sono strutture gerarchiche che suddividono i dati in base a criteri o regole di decisione. Vengono comunemente utilizzate per problemi di classificazione o di regressione.
- **K-Means Clustering**: è un algoritmo di machine learning non supervisionato che si concentra sul raggruppamento dei dati in cluster in base alla somiglianza delle loro caratteristiche.
- **Regressione Lineare**: viene utilizzata per modellare la relazione tra una variabile dipendente e una o più variabili indipendenti.
- **Random Forest**: combina diversi alberi di decisione per migliorare la precisione e ridurre il rischio di overfitting.
- **Metodi di Clustering** (ad esempio, DBSCAN): sono utilizzati per il raggruppamento di dati non etichettati in base alla loro densità.

- **Regole di Associazione:** servono per identificare regole o pattern di associazione nei dati.
- **Bayes Network:** si basano sulla teoria delle probabilità bayesiane e sono utilizzati per l'analisi probabilistica.

## 3.2 Reti Neurali Artificiali e Convoluzionali

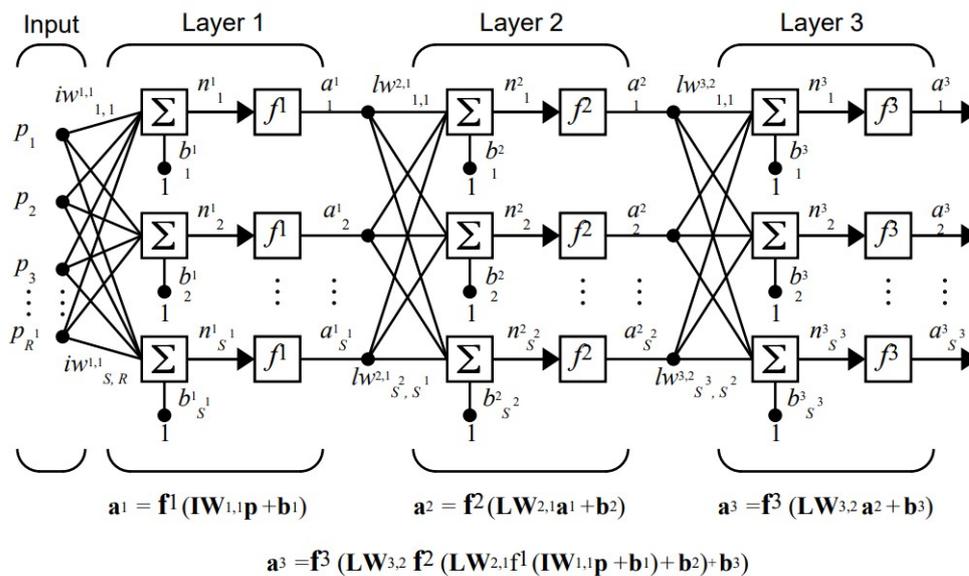
La flessibilità delle reti neurali le rende adatte a una vasta gamma di compiti e approcci a seconda delle esigenze specifiche dell'applicazione. Infatti, le reti neurali possono essere utilizzate sia in contesti di machine learning supervisionato che in contesti di machine learning non supervisionato o addirittura ibridi, a seconda dei dati a disposizione e il contesto specifico. Le reti neurali supervisionate vengono addestrate con coppie di input e output etichettati. In questo caso, la rete neurale impara a mappare gli input agli output, garantendo previsioni o classificazioni basate su nuovi dati. Ad esempio, un'applicazione di classificazione di immagini supervisionata, può addestrare una rete neurale a riconoscere animali basandosi su un dataset contenente immagini etichettate con i nomi degli animali da catalogare. Le reti neurali possono anche essere di tipo non supervisionato, in questo caso l'obiettivo è estrarre pattern o relazioni nascoste dai dati senza avere etichette o output noti. Questo può includere l'uso di reti neurali per la riduzione della dimensionalità, il clustering o altre applicazioni in cui è necessario individuare caratteristiche comuni dei dati e eventuali relazioni. Nella pubblicazione [6], gli autori un gran numero di pubblicazioni, inerenti alla valutazione dei danni nelle strutture composite attraverso approcci di machine learning. Gli studi presi in esame (Fig. 3.3) evidenziano la possibilità di risolvere problemi analoghi con approcci diversi. In particolare si evidenzia che *Artificial Neural Network* (ANN) e *Convolutional Neural Network* (CNN) sono quelli adottati comunemente e che riescono a garantire ottimi risultati per questo genere di problemi. Per questo motivo, è stato deciso di prendere in considerazione questi due approcci in questo elaborato. ANN e CNN sono entrambe categorie di reti neurali sviluppati per ambiti di applicazione diverse e con funzionamenti con caratteristiche diverse, come si vedrà in seguito.



**Figura 3.3:** Studi presi in esame da [6] rappresentano i tipi di modelli ML usati per SHM ad oggi per questo scopo

### 3.2.1 Reti Neurali Artificiali

Le reti neurali artificiali (ANN), sono progettate per elaborare informazioni in modo simile ai sistemi nervosi biologici di un cervello umano. Sono formate da strati di unità computazionali connessi tra loro. La struttura di una ANN è formata da molte unità base chiamate appunto neuroni artificiali, questi ricevono degli input, li elaborano, generano un output e lo passano ai neuroni successivi.



**Figura 3.4:** Esempio di rete con in input un vettore di valori  $p$  e 3 layer [51].

I neuroni sono organizzati in strati o layer. Una rete è composta da un layer di input, uno o più strati nascosti e un layer di output. Le reti di tipo *feed-forward*, ossia quelle che verranno usate in questo elaborato, gli input vengono elaborati in ogni strato prima di passare a quello successivo fino al layer di output, ciò significa che in questa tipologia di reti non esistono collegamenti tra neuroni dello stesso layer.

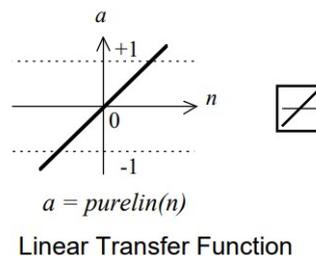
I neuroni di ciascun strato ricevono un input scalare  $p$ , ogni strato è collegato a tutti i neuroni di quello successivo tramite delle connessioni. Ogni neurone agisce mediante la funzione matematica 3.2.1 dove  $w$  sono i pesi (o *weights*),  $b$  i bias, a cui viene applicata una funzione di attivazione (o di trasferimento)  $f$ . Se si vuole operare una analogia con il caso biologico, i pesi corrispondono alla forza della connessione.

$$a = f(wp + b) = f(n) \quad (3.2.1)$$

I neuroni poi applicano una funzione di attivazione ai suoi input per determinare l'output del neurone. Le funzioni di attivazione hanno lo scopo di introdurre non linearità nel modello, consentendo alle reti neurali di apprendere relazioni più complesse. Alcune funzioni di attivazione comunemente usate in reti neurali sono:

- Funzione di attivazione lineare:

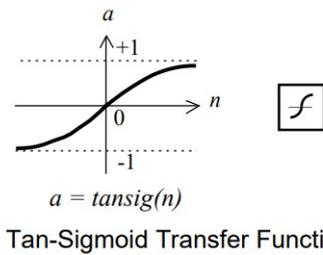
$$a = n \quad (3.2.2)$$



**Figura 3.5:** Esempio di funzione di trasferimento lineare [51].

- Funzione di attivazione tan-sigmoid:

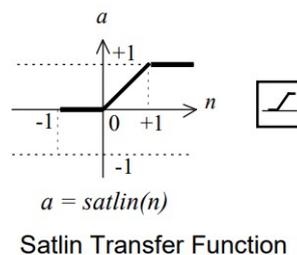
$$a = \frac{e^n - e^{-n}}{e^n + e^{-n}} \quad (3.2.3)$$



**Figura 3.6:** Esempio di funzione di trasferimento tan-sigmoid [51].

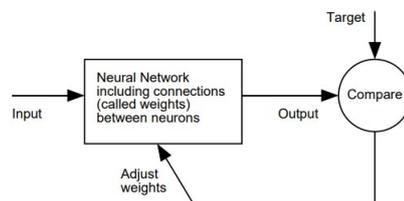
- Funzione di attivazione saturing lineare:

$$\begin{cases} a = 0 & \text{per } n \leq 0 \\ a = n & \text{per } 0 \leq n \leq 1 \\ a = 1 & \text{per } n > 1 \end{cases} \quad (3.2.4)$$



**Figura 3.7:** Esempio di funzione di trasferimento saturing lineare [51].

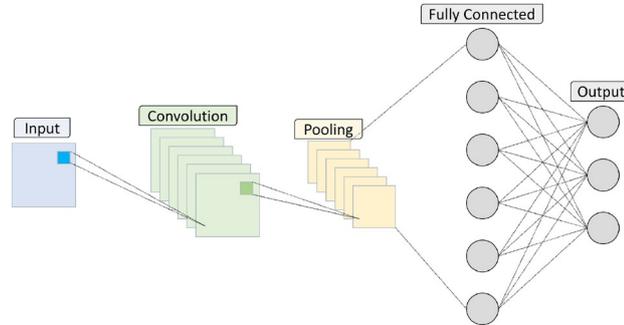
L'addestramento o *training* ha lo scopo di aggiornare i pesi delle connessioni per ridurre l'errore tra l'output previsto e quello reale (Fig. 3.8).



**Figura 3.8:** Esempio di addestramento di una rete neurale: i dati in input, dopo essere stati elaborati dagli strati della rete neurale, generano un output. Quest'ultimo, una volta comparato ai target reali, porta a una modifica adeguata dei valori dei pesi dei neuroni. [51].

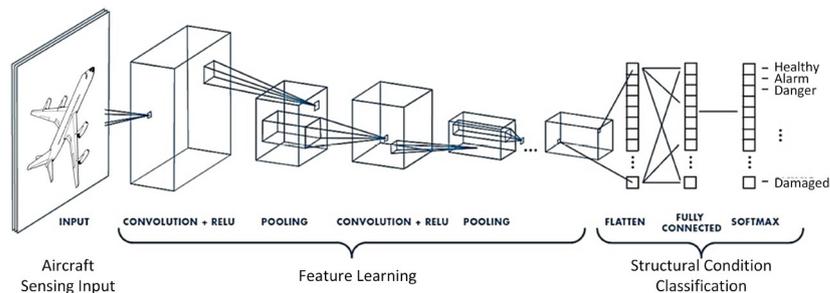
Le reti neurali artificiali sono utilizzate per risolvere una vasta gamma di problemi complessi, ma richiedono spesso un gran numero di dati di addestramento e un calcolo intensivo.

### 3.2.2 Reti Neurali Convoluzionali



**Figura 3.9:** Struttura di una Rete CNN [6].

Le reti convoluzionali prendono spunto dal funzionamento dell'elaborazione delle immagini del nostro sistema nervoso. Infatti, sono una architettura di deep learning ispirata ai meccanismi di funzionamento della corteccia visiva [22]. Queste, sono sviluppate principalmente per il riconoscimento di immagini, tuttavia le capacità di questo genere di rete si può espandere a qualunque genere di dato salvato in matrici o in alcuni casi tensori.



**Figura 3.10:** Esempio di una struttura tipica di una CNN, in questo caso usata per l'SHM [22].

La struttura di una rete di questo tipo differisce da una rete ANN tradizionale, in quanto in una ANN ogni neurone di uno strato sono connessi a tutti i neuroni dello strato successivo, le CNN, invece, agiscono mediante filtri, chiamati *kernel*. Questi lavorano in modo tale da tener conto della struttura spaziale dei dati, per poterne identificare dettagli, caratteristiche, e pattern comuni, questa è la principale differenza che garantisce alle CNN le capacità di classificare immagini complesse.

Una rete CNN, seppur non ha una struttura unica, un suo esempio è rappresentato in Figura 3.10, e si possono identificare alcuni elementi principali quali:

- **Strati convoluzionali:** questi layer permettono alle CNN di rilevare pattern visivi, come texture, bordi e forme. In queste layer vengono effettuate operazioni di convoluzione sui dati di input utilizzando filtri (kernel) per estrarre caratteristiche e dettagli dalle immagini. Si possono inserire layer di convoluzione in serie, in modo tale che l'output di un layer sia l'input di quello successivo. In questo modo si può migliorare l'accuratezza e discapito del tempo di allenamento. Il filtro o kernel, viene applicato alle informazione in input, facendolo scorrere sugli elementi della matrice, generando una mappa delle caratteristiche, o *feature map*. Questa operazione produce in output una nuova immagine o matrice per il layer successivo (Fig. 3.12), in cui il filtro ha evidenziato alcune caratteristiche, come bordi o dettagli. La *feature map* si calcola effettuando la somma dei risultati delle multipli-

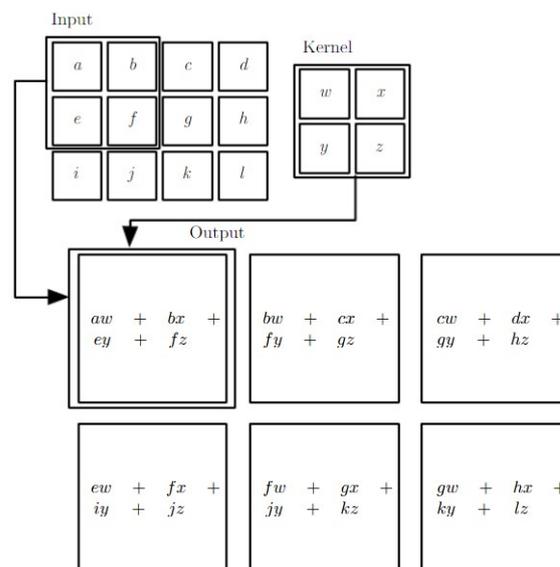


Figura 3.11: Esempio di operazione effettuata dal kernel [52].

cazioni degli elementi del kernel per una sezione di dimensioni appropriata della matrice di input (Fig. 3.11), in alternativa, viene effettuato il prodotto scalare. Le dimensioni del filtro vengono scelte per generare *feature map* diverse, o per alterare le dimensioni delle immagini o matrici in cui sono salvati i dati [55]. È possibile usare anche più filtri in un determinato layer convoluzionale, per concatenarne i risultati. La caratteristica di usare un unico filtro in tutta l'immagine, che viene spostato, applicandolo ad una porzione dell'immagine alla volta rende la CNN maggiormente invariante alla posizione dei dati, riducendo il fenomeno dell'overfitting.

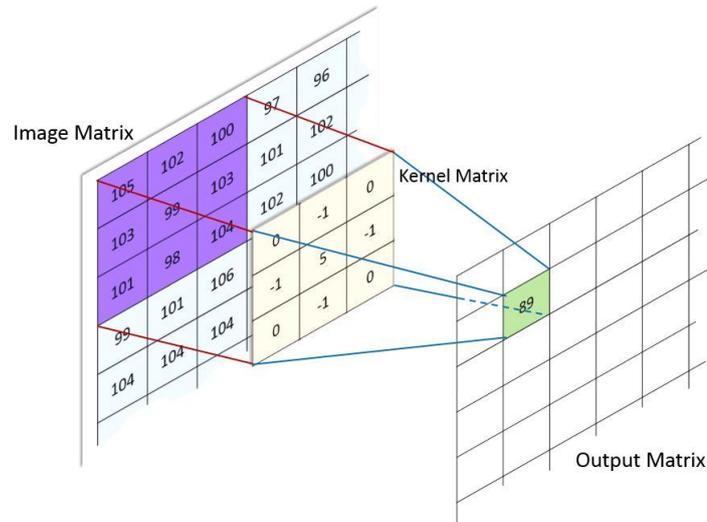


Figura 3.12: Esempio di kernel [55].

- **Funzioni di attivazione:** anche nelle reti neurali convoluzionali vengono usate le funzioni di attivazione con lo scopo di poter gestire eventuali non linearità. Le funzioni di attivazione, infatti, consentono alla rete di apprendere rappresentazioni più complesse dei dati. Le più usate in queste reti sono la sigmoid, ReLU e tanh (Fig. 3.13).

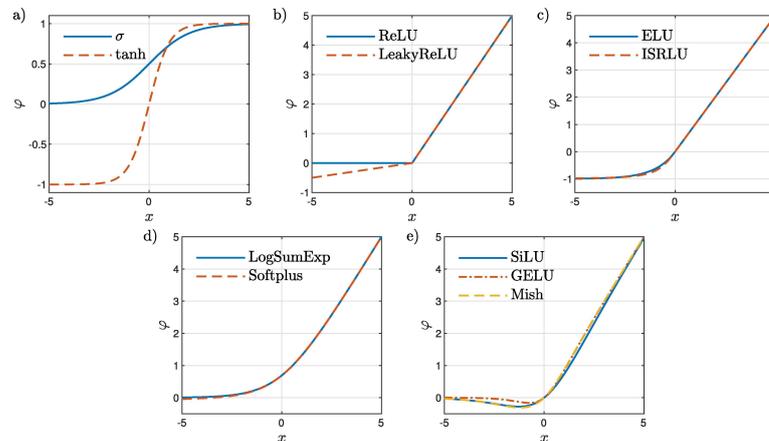


Figura 3.13: Esempi di alcune funzioni di attivazione usate in reti neurali artificiali e convoluzionali [56].

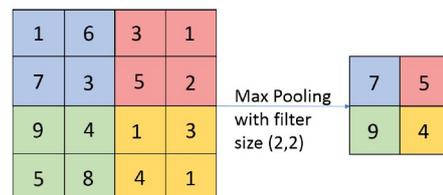
Generalmente viene usata più spesso la funzione ReLU (Rectified Linear Unit) per la sua efficacia ed efficienza computazionale (Eq. 3.2.5).

$$\begin{cases} ReLU(x) = 0 & \text{per } x \leq 0 \\ ReLU(x) = x & \text{per } x > 0 \end{cases} \quad (3.2.5)$$

Spesso viene adottata in alternativa alla ReLU, la Unità Lineare Rettificata con Perdita o detta anche LeakyReLU (Eq. 3.2.6). Tale funzione di attivazione è basata sulla ReLU, ma per i valori negativi in input non restituisce valori nulli in output. Graficamente si presenta a sinistra dello zero con una ridotta pendenza di tipo lineare, mentre a destra è identica alla ReLU classica.

$$\begin{cases} \text{LeakyReLU}(x) = \alpha \cdot x & \text{per } x \leq 0 \\ \text{LeakyReLU}(x) = x & \text{per } x > 0 \end{cases} \quad (3.2.6)$$

- **Strati di pooling:** vengono inseriti dopo i layer convoluzionali. Questi hanno lo scopo di ridurre la dimensione spaziale dei dati, ossia la dimensione delle immagini, riducendo così il numero di parametri e aumentando la robustezza del modello. Esistono due principali tipi di pooling, l'average pooling calcola il valore medio contenuto all'interno della patch (elemento su cui viene divisa l'immagine) e lo mette nella posizione corrispondente nell'output. Il max pooling invece, effettua una operazione analoga, ma in questo caso non effettua la media, ma ne calcola il massimo. Un esempio di max pooling è rappresentato in Figura 3.14.



**Figura 3.14:** Esempio di max pooling con filtro di dimensione (2,2) [22].

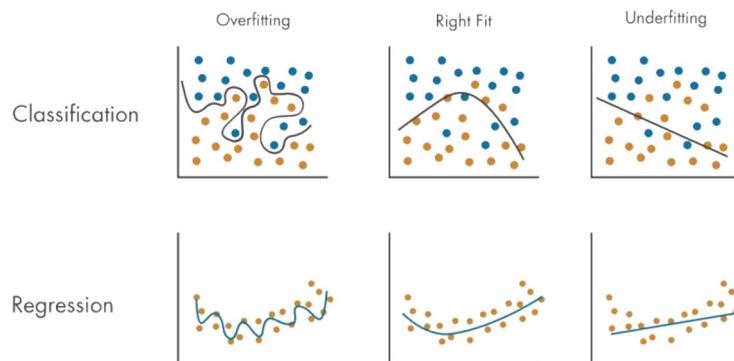
- **Layer di dropout:** è un layer opzionale, si può aggiungere alla rete per ridurre l'overfitting eliminando casualmente una frazione dei nodi nella rete. Questa riduzione casuale dei neuroni nella rete può essere utilizzata per simulare un gran numero di architetture diverse, il che garantisce una migliore generalizzazione della CNN.
- **Flattening:** viene usato in ogni CNN per cambiare la forma degli input. Dopo uno o più strati di convoluzione e pooling, le mappe delle caratteristiche vengono "appiattite" in un vettore di una dimensione prima di passare al fully connected layer.

- **Fully connected layer:** è un normale layer completamente connesso. Viene inserito alla fine della rete CNN comuni, ossia quelle usate al fine di classificare delle immagini. I Fully connected layer, corrispondono a semplici reti neurali artificiali, possono essere usati singolarmente o in più layer. Questi hanno lo scopo di elaborare le caratteristiche estratte e producendo una previsione o una classificazione. Tipicamente viene usato insieme a layer di tipo softmax per generare le previsioni desiderate, i neuroni all'uscita di quest'ultimo layer conterranno quindi la probabilità che un input della CNN appartenga a ciascuna delle classi desiderate.

### 3.3 Addestramento e Metriche

Durante il processo di addestramento risulta fondamentale dividere il set di dati in tre gruppi, il primo, viene chiamato set di addestramento o *training*, rappresenta la maggior parte dei dati, e servirà direttamente all'addestramento delle reti. Un secondo test è quello di validazione o *validation*, questo gruppo di dati anche se non usato per l'addestramento, viene usato durante tale processo, per assicurare una buona generalizzazione dell'algoritmo. Infine, il terzo gruppo di dati è quello di test, questo, ha lo scopo di verificare l'effettiva bontà della rete. L'addestramento della rete viene effettuato mediante la definizione di una funzione legata all'errore commesso dalla rete durante tale processo, chiamata *loss function*, l'ottimizzatore ha lo scopo di far variare i bias e i pesi della rete in modo tale da raggiungere il minimo di tale funzione. Questo processo avviene iterativamente, dividendo i set in gruppi più piccoli, chiamati *batches*, fornendo predizioni e successivamente valutandone l'errore e la relativa *loss function*. I dati, come già precisato, vengono divisi in piccoli gruppi (detti *batches*), la rete fornisce delle predizioni per ognuno degli elementi e l'ottimizzatore valuta l'errore commesso e stabilisce i nuovi parametri di pesi e bias. L'ottimizzatore, stima il gradiente della *loss function* e trova ad ogni iterazione i nuovi valori dei parametri affinché ci si avvicini sempre di più al punto di minimo della *loss function*. Si definisce iterazione, ogni aggiornamento di pesi per ogni *batch*; quando termina l'intero training set termina un'epoca o *epoch*. Per il processo di addestramento sono necessarie svariate epoche, fin quando la *training loss* (la *loss function* del set di *training*) raggiunge il minimo, e ciò dipende principalmente dalla complessità del problema, il numero di parametri liberi, la complessità della rete e il numero di dati a disposizione.

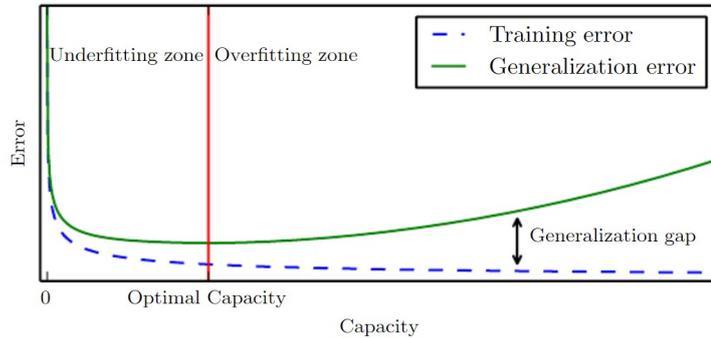
Un buon addestramento di una rete neurale artificiale o una convoluzionale deve avere buone capacità di generalizzazione, infatti l'utilizzo di reti neurali non ha lo scopo di interpolare i dati, bensì di replicare il processo che ha dato origine a quei dati [53]. Per questa ragione è importante definire la complessità della rete e il numero di dati in addestramento affini alla caratterizzazione del problema e al numero di parametri liberi. Ad esempio, il fenomeno dell'*underfitting* si verifica quando una rete è troppo semplice, questa infatti generalizzerà troppo, riproducendo risultati poco accurati o addirittura errati. Al contrario una rete troppo complessa, con un numero elevato di neuroni o layer, tenderà ad apprendere dai dati a disposizione, imparando "a memoria" il training ma perdendo la capacità di generalizzare correttamente il problema (esempio riportato in Figura 3.15), portando al fenomeno dell'*overfitting*. In altri termini l'*overfitting* si verifica quando la rete interpola i dati di *training*, perdendo la capacità di generalizzazione. Una prima risposta che spesso risulta efficace al problema dell'*overfitting* è incrementare il set di training, inserendo più casi da cui il sistema può apprendere.



**Figura 3.15:** Rappresentazione grafica dell'*underfitting*, *overfitting* e di una generalizzazione ottimale [27].

Ciò risulta lampante dalle curve di errore. In Figura 3.16 è rappresentato un esempio di ciò che avviene alla rete al variare della sua capacità di interpolare i dati in addestramento (ad esempio incrementando troppo la struttura di rete o il set di *training*). Una maggiore capacità può portare a un miglioramento degli errori durante il training, tuttavia incrementa l'errore di generalizzazione, osservabile su set di dati differenti da quello di training, come quello di validazione o di test.

Esistono alcuni approcci utili alla scelta della struttura di rete ottimale per la caratterizzazione del problema, come numero di neuroni e layer [53], tuttavia, questi non sono sempre efficaci e facilmente applicabili a tutti i casi. Per



**Figura 3.16:** Differenza fra la curva dell'errore di training (Training error), e quella di test (Generalization error). Finché la curva di training è maggiore di quella di test si è in presenza di underfitting, quando invece la curva di test cresce, quando quella di training diminuisce si è in presenza di overfitting [52].

questo motivo spesso si utilizzano tecniche euristiche, basandosi principalmente su approcci analoghi presenti in letteratura scientifica e all'esperienza. Una strategia alternativa riguarda la stabilizzazione strutturale [57], la quale consiste nel variare il numero di neuroni dei layer da un numero minimo a un numero massimo, valutando la configurazione migliore su un secondo gruppo di dati di validazione. Un'ulteriore tecnica tipicamente adottata è la regolarizzazione, questa generalmente viene applicata per prevenire l'overfitting. Tale tecnica agisce tramite un termine aggiuntivo inserito alla *loss function* dipendente dai pesi e dai bias dei neuroni. L'obiettivo è di limitare l'intervallo in cui i parametri possono variare, garantendo una migliore efficacia nel generalizzare i nuovi set di dati. Come per il caso precedente, anche le performance della regolarizzazione vengono valutate in base ad un set di validazione non adottato durante l'apprendimento. Questa tecnica aumenta l'efficienza del processo di addestramento, riducendo l'*overfitting* [52]. In alternativa alla regolarizzazione si può usare la tecnica di arresto anticipato o *early stopping*, che consiste nell'interrompere l'addestramento appena che la *loss function* inizia a presentare problemi di *overfitting* [53].

La *Loss function*, come anticipato, rappresenta una valutazione dell'errore commesso durante il processo di addestramento. Essa infatti, rappresenta una misura di quanto è efficace la rete nel predire correttamente i risultati durante il processo di addestramento. La *loss function* scelta dipende dal contesto, e dal problema che si decide di risolvere. Per esempio durante un processo di classificazione, la più utilizzata è la *cross entropy loss*, mentre per problemi di regressione viene comunemente utilizzata la *mean squared error* (MSE), questa infatti calcola l'errore quadratico medio fra valori predetti e valori reali [52].

La complessità intrinseca delle reti neurali, insieme alle diverse caratteristiche

legate alla loro struttura e funzionamento, fa sì che l'addestramento non possa essere semplicemente ridotto a un problema di ottimizzazione. Spesso risulta necessario esaminare una varietà di scenari, variando l'architettura della rete, le tecniche di addestramento, o la *loss function* per trovare la rete più performante per il compito assegnato.

# Capitolo 4

## Structural Health Monitoring

Con *structural health monitoring* (SHM) si intende un insieme di metodologie che hanno lo scopo di valutare lo stato di salute di una struttura durante la sua vita operativa. Ciò può avvenire in diverse modalità, in funzione dello scopo, il tipo di struttura e l'ambiente operativo. Questo genere di monitoraggio può essere di tipo distruttivo o non distruttivo, e può essere eseguito in tempo reale o meno, di tipo attivo o passivo. In questo elaborato, si approfondirà il monitoraggio di tipo non distruttivo, ossia quello che non prevede il danneggiamento della struttura per determinarne lo stato.

Nell'ottica di inserire un numero maggiore di componenti in materiale composito nell'ambito aeronautico, risulta essenziale implementare tecniche SHM. I materiali compositi, come visto nei capitoli precedenti, possono presentare difetti difficili da individuare, e meccanismi di danneggiamento più complessi di quelli dei materiali metallici usati comunemente. In particolare, i danni di impatto a bassa velocità generano fenomeni di danneggiamento BVID non identificabili con la semplice ispezione ad occhio nudo, in quanto la sezione danneggiata riguarda spesso gli strati più interni del laminato [9].

Con l'introduzione dei materiali compositi nella progettazione di strutture, è stato introdotto il concetto di *damage tolerance*; ossia le strutture in materiale composito devono poter sopportare un determinato livello di danno, senza comprometterne l'integralità e la funzionalità. Inizialmente i componenti in metallo delle strutture aeronautiche seguivano una progettazione *safe life*, ossia orientata a non subire danni durante il servizio utile. Tale progettazione prevedeva la sostituzione delle parti solo a termine vita. Il concetto di *safe life*, col tempo è stato sostituito da quello di *fail safe* [27]. In quest'ultimo caso la progettazione prevedeva che il componente potesse subire un danno, senza che questo risultas-

se catastrofico, garantendo il tempo di effettuare le riparazioni in sicurezza [30]. L'introduzione dei materiali compositi nelle strutture ha portato un ulteriore concetto, ossia quello di *damage tolerance* [30]. In questo caso, la struttura viene sovradimensionata nell'ottica di resistere ai carichi di esercizio per periodi prolungati, anche in presenza di danni. Vengono effettuati inoltre controlli periodici, che hanno la funzione di assicurarne l'integrità. In questo modo la sicurezza viene garantita mediante ispezioni non distruttive per valutare la resistenza residua della struttura. Ciò comporta un aumento dei costi di manutenzione, perché spesso analisi dettagliate prevedono lunghi tempi per lo smontaggio della struttura. Metodi alternativi di SHM, possono venir implementati direttamente nella struttura in tempo reale [22]. Garantendo l'individuazione dei danni nel momento in cui si verificano. Nel momento successivo all'individuazione si può procedere con un'ispezione approfondita, e accertare la reale entità del danno. Riducendo di molto i costi e il tempo associato alla manutenzione. Un ulteriore vantaggio dell'implementazione di metodi SHM consiste nella riduzione della massa della struttura, in quanto seguendo l'attuale criterio di *damage tolerance* molti componenti vengono sovradimensionati, incrementando la massa del velivolo.

## 4.1 Tipo di monitoraggio di danni da impatto

Le tecniche alla base dello *Structural Health Monitoring* si possono suddividere in base all'origine dei dati necessari alla loro implementazione [10]:

- Monitoraggio basato sui dati (*data-driven*): è basato sull'acquisizione di dati dai sensori posti sulla struttura da monitorare. I sensori possono essere montati esternamente o integrati alla struttura. Sensori esterni, sono facili da sostituire se danneggiati, tuttavia potrebbero alterare l'aerodinamica della superficie. Ciò non si presenta nel caso di sensori integrati, tuttavia, si potrebbe rendere la struttura più fragile localmente e quindi potrebbe essere necessario un inspessimento dei pannelli. I sensori adottati possono misurare variabili come deformazioni, temperature, accelerazioni e altri parametri chiave. I dati raccolti vengono analizzati per individuare cambiamenti nel comportamento strutturale nel tempo. L'analisi dei dati può coinvolgere tecniche di statistica, machine learning e algoritmi di rilevamento delle anomalie per individuare eventuali difetti o deterioramenti nella struttura.

- Monitoraggio basato sulla fisica (*Physics-based*): si basa sull'utilizzo di modelli matematici e simulazioni, per prevedere il comportamento strutturale in diverse condizioni. In questo genere di monitoraggio, si confrontano le misurazioni dei sensori, con le previsioni ottenute da modelli matematici, allo scopo di evidenziare anomalie nella struttura. Questo tipo di monitoraggio risulta particolarmente oneroso dal punto di vista computazionale; inoltre, risulta limitato nelle applicazioni pratiche, a causa della presenza di rumore nei segnali.
- Monitoraggio ibrido: si basa sia sulla raccolta e l'analisi dei dati reali tramite sensori, sia sull'uso di modelli fisici o matematici per migliorare la precisione e l'affidabilità del monitoraggio. Ha il vantaggio di fornire una maggiore capacità di rilevamento e previsione rispetto ai modelli presentati precedentemente. In quanto, avendo un approccio ibrido, presenta una conoscenza approfondita della struttura attraverso la modellazione, ma anche si adatta ai cambiamenti della struttura grazie ai dati in tempo reale.

Il monitoraggio può essere suddiviso ulteriormente in diretto o indiretto. Il monitoraggio diretto, si esegue attraverso varie tecniche di ispezione, cercando di individuare danni ad occhio nudo o mediante strumenti. Quello indiretto, invece, valuta il comportamento della struttura e lo confronta con quello della struttura non danneggiata. Un esempio di monitoraggio diretto, è quello che si basa sulla valutazione di discontinuità interne al materiale. In questo modo è possibile verificare la loro presenza mediante scansione ultrasonica C-Scan [49]. Questa tecnica si basa sulla velocità e l'attenuazione di un impulso ultrasonico che si propaga all'interno del materiale esaminato. Questa metodologia può essere applicata in due modi, la *through transmission technique*, prevede che l'onda propaghi attraverso al materiale e in presenza di un difetto la velocità e l'attenuazione dell'onda verrebbero alterati. Mentre la *pulse echo technique*, prevede la riflessione dall'onda.

Il monitoraggio indiretto si può suddividere in ulteriori due categorie: monitoraggio attivo e passivo. Questi si distinguono in base alla necessità o meno di un attuatore per rilevare i danni. In particolare il monitoraggio:

- Attivo: si effettua in un momento successivo al danno. Consiste nel sollecitare la struttura mediante un attuatore, e valutando la risposta del materiale è possibile verificare la presenza di danni interni.

- Passivo: si usano sensori per il monitoraggio degli impatti in tempo reale. Le perturbazioni dell'impatto viaggiano nella struttura e vengono registrate dai sensori disposti su di essa. Dall'analisi dei segnali si possono identificare le caratteristiche del danno. È importante tenere in considerazione che i segnali dipendono: dalla geometria della struttura, dalle proprietà del materiale adottato, dalle condizioni al contorno e dai parametri di impatto.

## 4.2 Valutazione tipo di impatto

Nei materiali compositi i danni da impatto si distinguono in un primo approccio in base alle caratteristiche osservabili. In particolare si distinguono in *Visible Impact Damage* (VID) e i *Barely Visible Impact Damage* (BVID). Nei VID i danni di impatto sono facilmente identificabili, causati da impatti a media-alta velocità; mentre nei BVID, anche se gli impatti compromettono la struttura, sono difficilmente identificabili. Questi ultimi sono generalmente associati ad urti a bassa velocità e si traducono in una riduzione della resistenza del materiale.

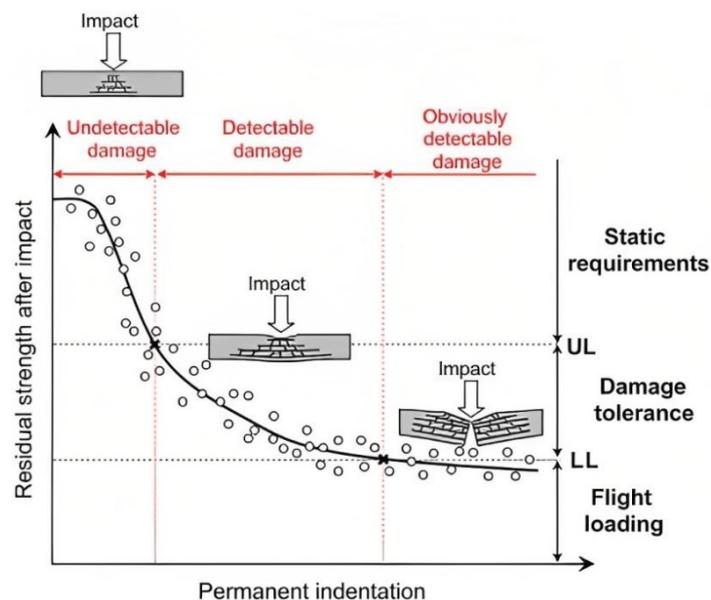


Figura 4.1: Andamento della resistenza residua in funzione del tipo danno [19].

La determinazione dei danni da impatto è associata sia alla velocità, che alla massa del corpo impattante. Questi infatti, identificano le caratteristiche dell'impatto, come la durata dell'evento, e la propagazione delle perturbazioni nella struttura. In base alla velocità dell'impattatore è possibile identificare i seguenti casi [59]:

- *Low Velocity Impact (LVI)*: identificano gli impatti a bassa velocità, inferiore a  $8m/s$ . Nei materiali compositi, impatti a bassa velocità sono caratterizzati, da una risposta legata fortemente alla geometria della struttura. È da prestare particolare attenzione a tali impatti in quanto possono causare danni che non sono facilmente identificabili, ossia facenti parte alla categoria BVID.
- *Intermediate Velocity Impact (IVI)*: a velocità intermedia, compresa tra  $8m/s$  e  $70m/s$ . Sono gli impatti che si potrebbero verificare per un aereo che impatta con volatili, o detriti in pista durante la fase di decollo o di atterraggio.
- *High Velocity Impact (HVI)*: ad alta velocità, questi includono gli impatti balistici e sono generalmente oggetto di studio nel campo militare. Gli impatti HVI interessano una zona specifica della struttura, senza coinvolgerla totalmente. Di conseguenza, mostrano un comportamento localizzato, indipendente dalla geometria della struttura.
- *Hyper Velocity Impact* : ad iper-velocità, compresa tra  $30km/s$  e  $70km/s$ . Sono gli impatti che interessano principalmente l'ambito spaziale.

Durante un impatto, si generano onde elastiche sulla superficie che si propagano sulla piastra a partire dal punto in cui si verifica l'impatto. La propagazione di queste onde sulla superficie del laminato è fortemente influenzata dalla durata dell'evento. Per tempi di impatto molto brevi (Fig. 4.2a), inferiori al tempo necessario perché l'onda si propaghi lungo lo spessore della piastra, le onde si propagano come onde tridimensionali. Per durate di impatto più lunghe, le onde che si propagano sono di tipo flessionale e trasversale (Fig. 4.2b). Infine, per durate di impatto sufficientemente lunghe, superiori al tempo necessario per raggiungere le estremità della piastra, prevale la modalità di vibrazione più bassa del sistema impattore-piastra (Fig. 4.2c). Gli ultimi due casi sono quelli che producono danni BVID, e saranno l'argomento principale di questo elaborato.

Nell'articolo [20] si propone una classificazione degli impatti basata sul rapporto di massa tra l'impattore,  $m_i$ , e il pannello,  $m_p$ . Si evidenzia che è la massa dell'impattore a determinare la durata e le caratteristiche dell'impatto, piuttosto che la sola velocità. Si distinguono gli impatti in base al rapporto di massa in:

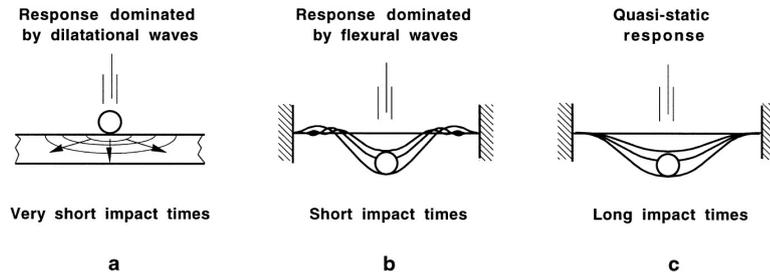


Figura 4.2: Tipi di risposta del materiale in funzione al tipo di impatto [20]

- Impatti a massa piccola: il rapporto delle masse è  $m_i/m_p < 0.23$ . Durante tali impatti si producono onde tridimensionali come quelle rappresentate in Figura 4.2b.
- Impatti a massa intermedia: corrispondono a impatti con masse comprese nel range  $0.2 < m_i/m_p < 2$ . Sono governati dai modi di vibrare del sistema, generando carichi di picco maggiori rispetto alle masse grandi. Può essere modellato similmente a quello in Figura 4.2c, apportando delle opportune correzioni [20].
- Impatti a grande massa: il rapporto delle masse è  $m_i/m_p > 2$ . Tali impatti sono caratterizzati da una risposta quasi statica: nelle fasi iniziali domina un'onda flessionale che raggiunto il suo limite si tramuta in una deformazione statica della piastra. Il comportamento è analogo a quello rappresentato in Figura 4.2c.

Si è riscontrato che il rapporto di massa determina la durata dell'impatto e l'evoluzione del sistema. Gli impatti di breve durata, sono caratterizzati dalla propagazione di onde che non sono influenzate dalle dimensioni e dalle condizioni al contorno della piastra (simili agli impatti balistici). Al contrario, gli impatti di lunga durata causano una risposta quasi statica, influenzata dalla dimensione della piastra e dalle condizioni al contorno. In [20], Olsson dimostra che, a parità di energia, gli impatti caratterizzati da impattatori con masse più contenute possono causare danni maggiori rispetto a quelli con masse più grandi.

#### 4.2.1 Forza teorica di delaminazione per impatti di grandi masse

La forza d'impatto massima è un parametro essenziale per determinare se un impatto abbia generato un danno o meno. Negli elaborati di tesi [1] e [2], si

stima la forza di delaminazione del pannello preso in considerazione in questo studio, mediante la teoria illustrata da Olsson in [48]. Olsson descrive il processo che porta alla formazione di danni in seguito ad urti in un laminato, proponendo delle formule ai fini di stimare la forza teorica di delaminazione.

Il caso di interesse è quello inerente agli impatti di grande massa, poiché possono generare danni nel materiale non identificabili ad occhio nudo. Urti che presentano impattatori con una massa grande, sono caratterizzati da un tempo di contatto sufficientemente lungo per generare una risposta quasi statica: presentando il picco della forza di contatto e le deformazioni della piastra in fase. Questo tipo di impatti possono causare danni da delaminazione nel materiale e sono facilmente associabili alla caduta di attrezzi sulla superficie di un aeroplano, o ad altri impatti che potrebbero verificarsi durante la vita operativa. Questo tipo di urti sono alla base dei danni di tipo BVID, la cui stima risulta necessaria. La formula teorica per predire la massima forza di contatto, prima di incorrere in delaminazione, per impatti di grande massa, è [48]:

$$F_{del} = \pi \sqrt{\frac{32D^* \cdot G_{IIC}}{n+2}} \quad (4.2.1)$$

$D^*$  indica la rigidezza del pannello nel punto in cui avviene l'urto,  $G_{IIC}$  è la tenacità a taglio (*Mode II*) fra le lamine che compongono il pannello e  $n$  indica quante delaminazioni sono già presenti nel pannello, nel caso in cui il pannello sia integro  $n=0$ .

Per stimare  $D^*$ , in [1] viene calcolata la rigidezza equivalente del pannello irrigidito suddividendo il pannello in aree e calcolando le rigidezze equivalenti di ciascuna area [64]. In questo modo, è possibile considerare il contributo degli irrigidimenti, che non è previsto nella trattazione di Olsson [48]. L'Equazione 4.2.1 permette di calcolare separatamente le matrici di rigidezza per gli irrigidimenti e per la flangia. Ne consegue che la forza di delaminazione non risulta unica per l'intero pannello irrigidito, ma dipende dalla parte considerata. Infine, si considera che il momento flessionale indotto durante l'impatto venga ripartito tra i singoli componenti in proporzione alla loro rigidezza flessionale; per questo motivo, la rigidezza equivalente del pannello è data dalla somma delle rigidezze delle singole parti.

$$D^* = \sqrt{\frac{D_{11}D_{22}(A+1)}{2}} \quad \text{con} \quad A = \frac{D_{12} + 2D_{66}}{\sqrt{D_{11}D_{22}}} \quad (4.2.2)$$

La stima della forza di delaminazione risulta fondamentale ai fini di proget-

tazione, in quanto rappresenta il punto in cui il pannello smette di comportarsi in modo elastico ed hanno inizio fenomeni di danneggiamento, quali la delaminazione. La tabella seguente riassume i risultati stimati in [1] per il caso in esame.

	$F_{del}$ [N]	$D^*$ [GPa · mm <sup>3</sup> ]	$G_{IIC}$ [N/mm]
Pannello	3922	139.13	0.7
Pannello Irrigidito	8420	641.40	0.7

**Tabella 4.1:** Valori stimati in [1] delle forze di delaminazione teoriche del pannello in presenza e assenza degli irrigidimenti.

Dalla Tabella 4.1, è evidente che il pannello irrigidito risulta più resistente di quello non irrigidito. La possibilità di definire un approccio teorico, per determinare il limite superiore al quale ci si aspetta la delaminazione del materiale, risulta fondamentale per poter introdurre una metodologia SHM basata sulla stima della forza di impatto. Questa tecnica di monitoraggio, consiste nel ricostruire la forza di contatto massima, che si sviluppa durante l'urto, e di confrontarla con quella teorica associata alla delaminazione. Tuttavia è importante precisare che le equazioni adottate per la stima della forza di delaminazione, sono valide nell'ipotesi che l'impattatore abbia una grande massa, e per cui questo approccio rappresenta un valore indicativo. Può essere considerato come un riferimento durante la progettazione e per la valutazione di alcuni impatti che un aeromobile potrebbe incontrare durante la sua vita operativa, anche se non copre tutti i possibili scenari.

## 4.3 Metodologie SHM

Nel campo del monitoraggio strutturale, esistono diversi approcci proposti in letteratura. Questi possono focalizzarsi sulla valutazione di danni già esistenti, sulla previsione delle caratteristiche dell'impatto e sull'analisi per stimare i danni.

### 4.3.1 Tecniche Attive

Si usano specifici sensori per diagnosticare la presenza di danni interni alla struttura, utili soprattutto per danni non facilmente distinguibili ad occhio nudo. Ad esempio i metodi basati sulle *guided waves*, o onde guidate, consistono nell'emissione di onde sonore da parte di attuatori, queste viaggiano all'interno della

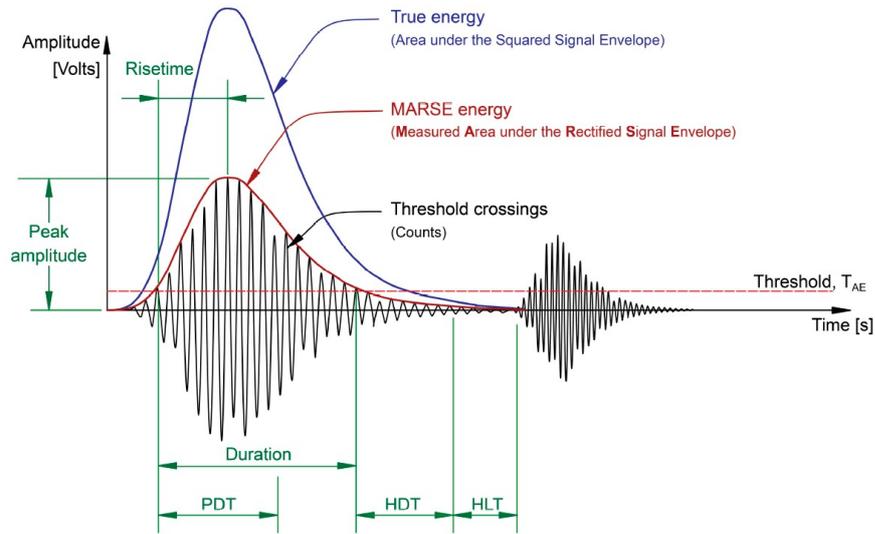


Figura 4.3: Parametri onda acustica [3].

struttura, e alla presenza di un danno, vengono distorte. Il processo di individuazione del danno avviene mediante il confronto tra il segnale ricevuto dai sensori e quello che ci sarebbe stato in assenza di danno. Tramite questo tipo di monitoraggio, è possibile identificare la categoria di danno nella struttura e la relativa posizione [10]. Inoltre, risulta possibile associare un indice di danno al segnale misurato, evidenziandone l'entità [8]. Sensori comunemente usati a questo scopo sono di tipo piezoelettrico, in quanto sono facilmente tramutabili da ricevitori a attuatori, di basso costo, e facilmente integrabili nella struttura. In [10] gli autori propongono l'inserimento di un parametro chiamato *Health Indicator* (HI), allo scopo di indicare lo stato di salute della struttura in tempo reale, traducibile nella perdita di resistenza strutturale.

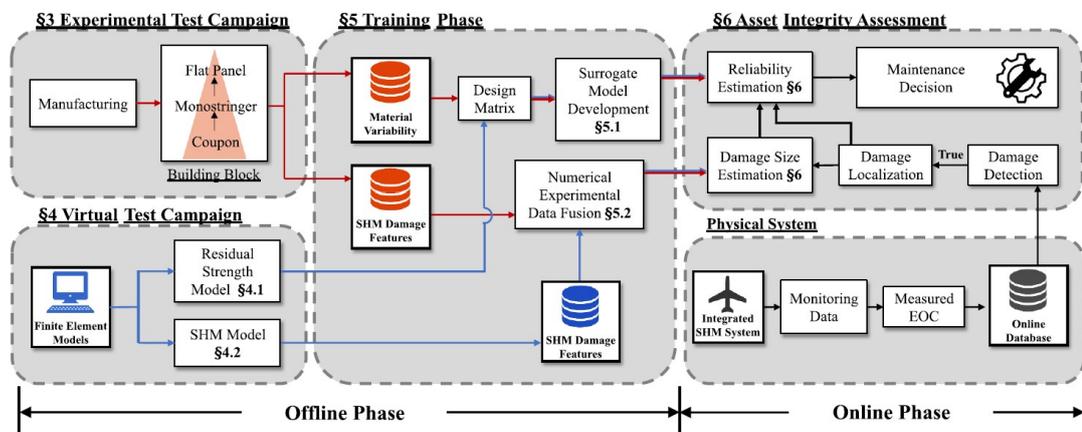
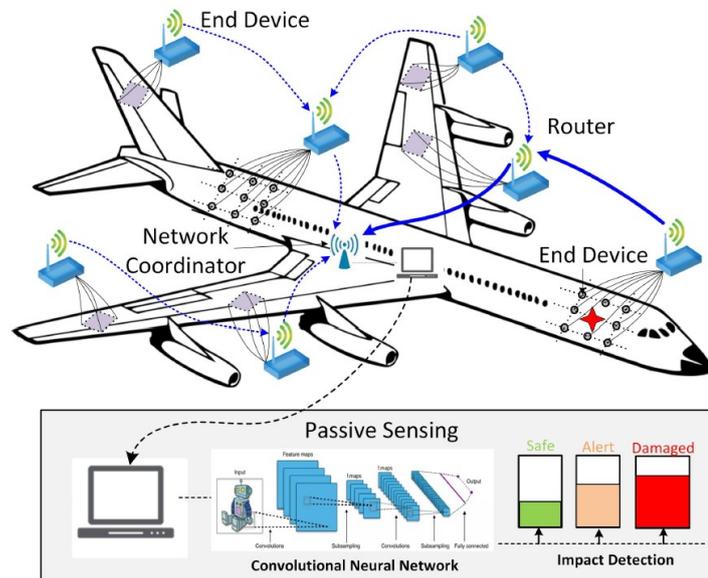


Figura 4.4: Panoramica dei componenti del framework. I colori rosso e blu indicano rispettivamente i flussi di informazione dalla campagna sperimentale e dai modelli numerici [10].

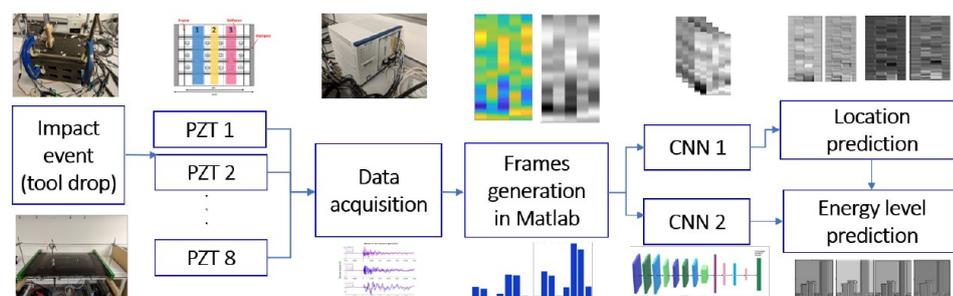
Le tecniche di tipo attivo, tuttavia presentano anche diversi svantaggi. Ad esempio, la presenza di strutture con geometrie complesse e di vincoli che potrebbero causare la riflessione dei segnali, possono rendere difficile l'interpretazione dei dati registrati dai sensori. Inoltre, è necessario applicare delle adeguate correzioni a causa di diverse variabili che potrebbero alterare le caratteristiche della struttura e dei segnali, come la temperatura operativa e l'umidità [8]. Infine, bisogna tenere conto dell'elevato costo per la campagna di acquisizione dati, considerando i parametri che influenzano la propagazione delle onde utilizzate, come le variazioni di fase, ampiezza e velocità di propagazione [9].

### 4.3.2 Tecniche Passive



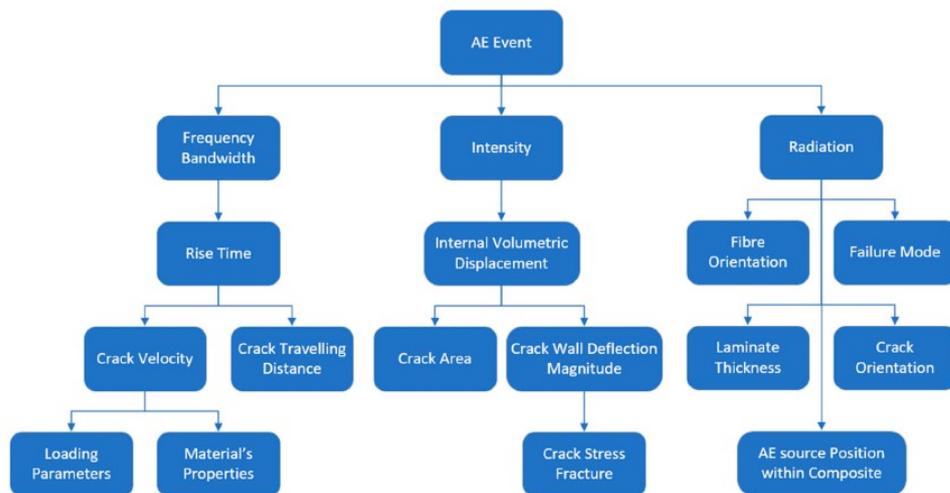
**Figura 4.5:** Rilevamento passivo con reti di sensori wireless incorporati e CNN. Dispositivi di rilevamento passivo wireless sono montati su un aeromobile. Una rete di sensori wireless viene stabilita per svolgere le funzioni di rilevamento degli impatti, comunicazione dati e elaborazione del segnale. [22]

Nelle tecniche passive, l'identificazione del danno avviene in tempo reale, senza l'uso di attuatori, ma solo mediante sensori disposti sulla superficie che registrano i segnali ricevuti durante l'impatto. È possibile predisporre le strutture del velivolo con dei materiali che incorporano già i sensori, ottenendo delle strutture intelligenti ad esempio quella osservabile in Figura 4.5. I segnali misurati dai sensori possono venir elaborati seguendo un approccio basato sul *machine learning*, in modo tale da poter determinare la posizione dell'impatto, la sua energia, o l'entità del danno [22].



**Figura 4.6:** Metodologia usata da [22] per strutturare il sistema SHM di tipo passivo, per la caratterizzazione degli impatti. Con due reti CNN, una per predire la posizione e l'altra per stimare i livelli di energia

I sensori adottati possono registrare diversi tipi di parametri, quali: perturbazioni dovute alle onde guidate (onde acustiche o ultrasuoni), o alcune grandezze meccaniche, come accelerazioni, spostamenti o deformazioni nei pressi dei sensori. Una volta acquisiti i dati si procede nella generazione degli input da analizzare in tempo reale. Con l'implementazione della potenza di calcolo, e tecnologie sempre più precise di *machine learning*, le misurazioni vengono tradotte in matrici o immagini per l'analisi mediante approcci di questo genere.



**Figura 4.7:** Dettaglio di una emissione acustica dovuta a un fenomeno di danneggiamento e i parametri che la legano alle caratteristiche del danno [3].

In [3] gli autori propongono un approccio alternativo, che si basa sull'emissione acustica generata durante il processo di danneggiamento. Durante la formazione del danno, si genera un'onda acustica caratteristica, che viene registrata da opportuni sensori piezoelettrici. Analizzando questi dati, è possibile riconoscere il tipo di danno che ha causato l'emissione acustica (Figura 4.7). Questo metodo valuta i parametri principali dell'onda acustica, per distinguere tra diversi tipi di danno che si possono verificare internamente alla struttura. Ad esempio, è possibile distinguere il danno alle fibre, dalla delaminazione o dal danno alla matrice; come mostrato negli esempi in Figura 4.9. Questo approccio, tuttavia, risulta difficilmente applicabile in un ambiente come quello aeronautico, in cui ci sono strutture complesse e notevoli fonti di rumore.

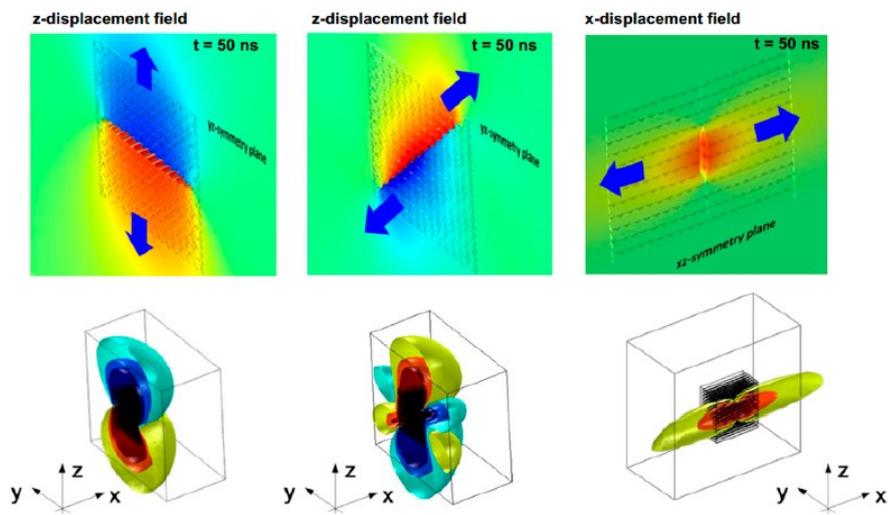


Figura 4.8: (sinistra) modo I failure interfibres, (centro) modo II failure interfibres, (destra) modo I failure fibre con asse-Z lo spessore della lamina [3].

Damage Mechanism	Form of Signal
Matrix cracking (A class)	
Fibre-matrix debonding (B class)	
Fibres breaking (C class)	
Delamination (D class)	

Figura 4.9: Esempi di onde acustiche in funzione al tipo di danno [3].

## 4.4 Tecniche adottate

Questa tesi si concentra sull'analisi delle caratteristiche degli impatti inclinati, al fine di porre le basi per un modello di Structural Health Monitoring (SHM) di tipo *data-driven*, potenzialmente implementabile in tempo reale. L'intenzione è di analizzare nel dettaglio gli impatti inclinati e verificare se le strategie note sono applicabili anche per impatti non perpendicolari. In letteratura, gli algoritmi di tipo passivo generalmente considerano impatti perpendicolari, mentre i pochi risultati ottenuti riguardanti gli impatti inclinati hanno generato difficoltà nella predizione delle caratteristiche di impatto, come ad esempio il picco di forza e l'inclinazione [2]. Lo scopo è quello di esaminare diverse metodologie per caratterizzare correttamente questo tipo di impatti e valutarne l'efficacia. Nella sezione successiva, verranno presentate le caratteristiche del modello analizzato: un pannello irrigidito in materiale composito, modellato mediante il software agli elementi finiti Abaqus. Saranno effettuate numerose simulazioni di impatti, variando la posizione, la velocità, l'inclinazione e la massa dell'impattatore. In ciascuna simulazione, verranno raccolti i segnali di spostamento in alcuni nodi, che avranno lo scopo di emulare il comportamento dei sensori disposti sulla superficie del pannello. Infine, i dati raccolti dalle simulazioni saranno utilizzati per addestrare due tipi di reti neurali: Reti Neurali Artificiali e Reti Neurali Convoluzionali; al fine di predire la forza massima sviluppata durante l'impatto e gli angoli di impatto. Le reti neurali artificiali sono spesso un approccio comune per l'implementazione degli attuali algoritmi SHM passivi, mentre quelle convoluzionali, nonostante abbiano già dimostrato ottime capacità di predizione, presentano una maggiore complessità nella struttura e nella gestione dei dati in input, rendendole generalmente più difficili da implementare. La scelta di queste due architetture di rete è motivata dalla necessità di confrontare le predizioni e verificare se l'aumento di complessità associato all'utilizzo di reti convoluzionali sia giustificato da un'accuratezza migliore.

# Capitolo 5

## Modello FEM

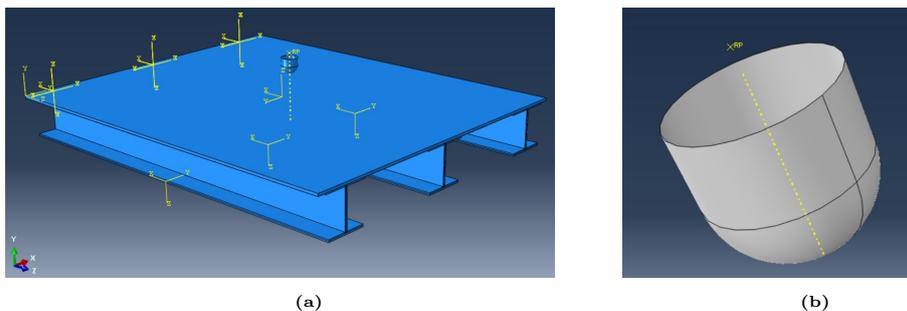
Lo scopo di questa tesi è di sviluppare una strategia affinché si riesca a determinare con efficacia la ricostruzione degli impatti angolati mediante reti neurali. La struttura adottata viene modellata con il software agli elementi finiti (FEM) Abaqus Explicit. Il modello studiato consiste in un pannello irrigidito in materiale composito, che viene impattato da un proiettile con punta semisferica. Tale struttura riprende, quella sviluppata nell'articolo di Falgiani Falzon in [31] e nelle tesi di laurea di Cappellini [1] e Giacomini [2]. Mentre in [31] e [1], gli autori hanno adottato solo impatti perpendicolari alla piastra; nella tesi di laurea di Giacomini [2] sono stati introdotti anche impatti inclinati, non restituendo risultati accettabili.

Per migliorare le predizioni degli impatti angolati, è stato incrementato il numero di simulazioni effettuate, per un totale di 1800. Ciò è motivato dal fatto che le dimensioni del set di dati, necessari all'addestramento delle reti, è associato ai gradi di libertà del sistema da simulare. Per cui, introducendo gradi di libertà in più, associati agli angoli di impatto, potrebbe non essere stato sufficiente il numero di simulazioni adottate in [2]. Incrementare il set di *training*, potrebbe migliorare le predizioni e ridurre eventualmente il fenomeno dell'*overfitting* (se presente). Per garantire l'elevato numero di simulazioni, risulta necessario, alleggerire il modello originario, in modo che si possano effettuare più simulazioni riducendo il tempo totale necessario. A tale scopo, vengono sviluppati due modelli: un modello chiamato "Mesh Fine", che presenta una mesh fitta, conforme alle caratteristiche del lavoro di [2]; e un nuovo modello, più veloce, che introduce importanti semplificazioni, chiamato "Semplificato", che verrà usato per l'addestramento delle reti neurali. Il modello Mesh Fine, è rappresentativo del caso reale, ed ha lo scopo di validare e confrontare i dati ottenuti dal modello

Semplificato. Garantendo che il modello Semplificato abbia un comportamento confrontabile con quello reale. Mesh Fine presenta superfici coesive fra le interfacce dei pannelli e degli irrigidimenti, in modo da simularne l'incollaggio, inoltre è implementato il relativo danneggiamento di tale materiale. Nel modello Semplificato invece, sono assenti i fenomeni di danneggiamento e gli elementi coesivi, inoltre la mesh è più grossolana. Tali semplificazioni sono motivate dal fatto che l'attuale tesi rappresenta un punto di partenza per l'applicazione di tecniche SHM agli impatti inclinati. Individuando eventuali strategie basate sul *machine learning* per migliorarne le predizioni. Inoltre, i range di forze di impatto adottati, sono inferiori a quelli che potrebbero generare un danno alla struttura. In questo contesto, infatti, è stato verificato che gli impatti considerati non raggiungessero le condizioni di danno, attraverso il modello "Mesh Fine", prima di procedere alle semplificazioni.

## 5.1 Geometria del modello

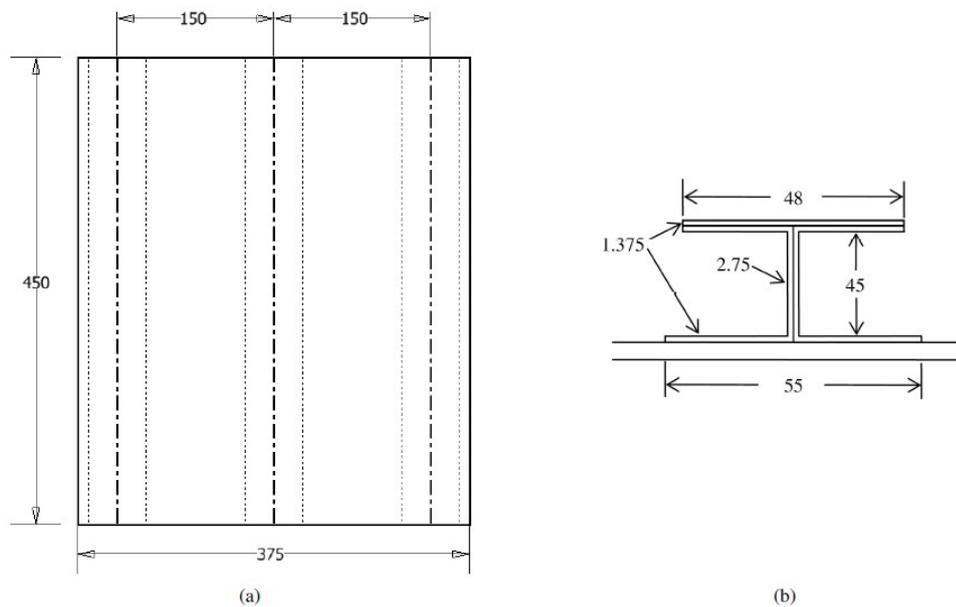
Per ragioni di continuità, la geometria del modello riprende quella presente in [1], [2], e [31]. Il pannello irrigidito in materiale composito, è composto da una piastra superiore rettangolare e tre travi ad "I". L'impattatore è stato modellato a forma di proiettile con una punta semisferica.



**Figura 5.1:** a) Pannello irrigidito. b) Impattatore.

Il pannello irrigidito, raffigurato in figura 5.1a, è disposto nel piano XZ e presenta una lunghezza di  $375\text{mm}$  e una larghezza di  $450\text{mm}$ . Le parti che lo compongono, sono modellate come solidi 3D deformabili, unite nel menu *assembly* di Abaqus. La superficie piana del pannello è definita come un solido di spessore di  $3\text{mm}$  in materiale composito, connessa mediante un sottile strato di materiale coesivo, di  $0.130\text{mm}$ , alle travi sottostanti. Le travi ad "I" sono composte da 2 elementi a "C", tenuti insieme da un sottile strato di "materiale coesivo". L'impattatore viene definito come una superficie 2D, modellata come una semisfera

di  $12.7mm$  di diametro con un corpo cilindrico alto  $10mm$ . All'impattatore è stata attribuita una massa mediante la proprietà di tipo *Inertia*, associata ad un *Reference Point*. Dato che questo modello ha lo scopo di indagare le capacità di predire correttamente la forza di contatto massima per gli impatti inclinati, e non studiare nello specifico il fenomeno del danneggiamento; nel modello Semplificato si è optato per eliminare le superfici coesive, e sostituirle con dei *Constraints* di tipo *Tie*.



**Figura 5.2:** Dimensioni del pannello preso in esame [2].

## 5.2 Materiali

Per la realizzazione del materiale composito degli irrigidimenti e del pannello è stato utilizzato il materiale HTA/6376C, definito in Abaqus come *Composite* nella sezione *section*. Così è possibile definire le direzioni delle lamine e l'ordine di impilaggio. Le lamine in fibra di carbonio di spessore  $0.125mm$  sono impilate facendo riferimento all'asse Z dell'intero modello. Per la piastra superiore il layup è composto da 24 lamine con orientazione  $[+45/-45/0/+90]_{3S}$  per uno spessore totale di  $3mm$ . Gli irrigidimenti invece, sono composti da un layup, con orientazione pari a  $[+45/-45/0_3/+90/0_3/+45/-45]$  per un totale di 11 lamine ed uno spessore di  $1.375mm$ . L'adesivo è definito con il materiale FM300-2M e assegnato ad Abaqus inserendo la proprietà *Cohesive* nel menu *section*.

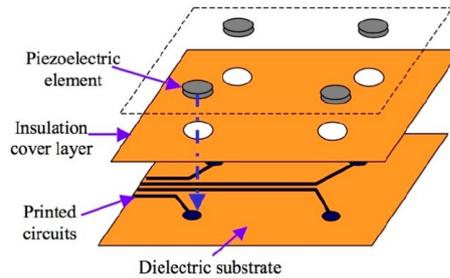
Proprietà	HTA/6376C	FM300-2M
Densità	1590kg/m <sup>3</sup>	1130kg/m <sup>3</sup>
$E_1$	145GPa	2.32GPa
$E_2$	10.3GPa	907.5MPa
$E_3$	12.1GPa	907.5MPa
$\nu$	-	0.28
$\nu_{12}$	0.301	-
$\nu_{13}$	0.5	-
$\nu_{23}$	0.495	-
$G_{12}$	5.3GPa	-
$G_{13}$	5.275GPa	-
$G_{23}$	3.95GPa	-
Max damage		
Stress nominale: normale	-	61MPa
Stress nominale: dir. I	-	49.1MPa
Stress nominale: dir. II	-	61MPa
Damage evolution		
Energia di frattura	-	260J/m <sup>2</sup>

**Tabella 5.1:** Proprietà dei materiali.

### 5.3 Posizione dei sensori

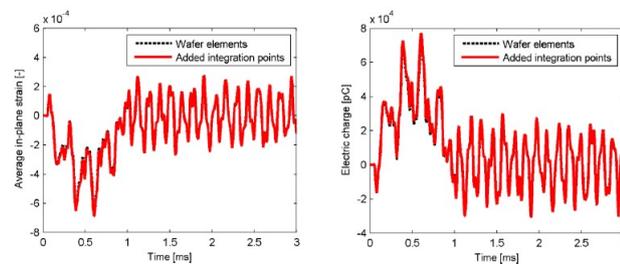
Le scelte del tipo, la posizione e il numero di sensori non risulta banale, infatti queste possono influire sul processo di apprendimento e l'accuratezza delle predizioni delle reti neurali. Un numero di sensori troppo basso può ridurre l'accuratezza del sistema SHM, tuttavia un numero troppo elevato può essere difficile o addirittura impossibile da integrare in un provino reale [18]. In ambito sperimentale, vengono usate tecniche che fanno uso di onde guidate (che possono essere ultrasuoni o onde acustiche) e sensori di tipo piezoelettrico per registrare tali segnali. Grazie al loro spessore ridotto, frequentemente questi sensori vengono integrati nel pannello durante il processo di produzione, come mostrato nella figura 5.3, realizzando in questo modo uno *Smart Layer*.

Sensori piezoelettrici in piombo zirconato di titanio (PZT), sono comunemente usati per le loro ottime caratteristiche di sensibilità. Generano una tensione elettrica misurabile a partire dalle onde elastiche indotte dall'impatto sulla superficie della struttura. Infatti, la relazione tra, tensione generata per effetto



**Figura 5.3:** Configurazione base di un layer di sensori piezoelettrici [18].

piezoelettrico e la somma delle deformazioni nel piano della zona di interfaccia, risulta essere lineare [34]; come rappresentato in Figura 5.4.

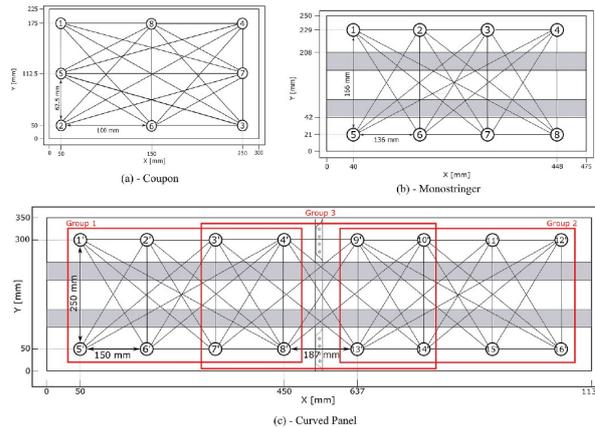


**Figura 5.4:** Raffigurazione della relazione lineare che c'è fra tensione nel sensore PZT e deformazioni nel punto del sensore. a) Media delle deformazioni misurate nel piano con un sensore *Wafer*, modellato come un solido legato con un *constraint* di tipo *tie* sulla superficie del pannello, e un sensore modellato come punti di integrazione nei nodi che delimitano la superficie del sensore. b) Le corrispondenti cariche elettriche. [34].

Un altro tipo di sensori utilizzati sperimentalmente sono gli accelerometri. Ad esempio, quelli basati sui materiali piezoelettrici possono raggiungere elevate frequenze di campionamento, in modo tale da misurare i valori delle accelerazioni durante l'impatto [27].

Nonostante, dal punto di vista applicativo, l'uso di questi sensori è conveniente grazie alla loro elevata frequenza di campionamento, compattezza e massa ridotta, che ne facilitano l'integrazione nella struttura. Nella modellazione agli elementi finiti, risulta difficilmente compatibile con le risorse computazionali a disposizione simulare sensori con elevate frequenze di acquisizione, questo infatti, si traduce in elevati tempi di calcolo e memoria necessaria per salvare i dati di ciascuna simulazione. Per questo motivo, nelle simulazioni agli elementi finiti, invece di richiedere informazioni sulle deformazioni o sulle accelerazioni, caratterizzate da segnali ad alte frequenze, si richiedono gli spostamenti, che presentano minori variazioni, come mostrato in [23]. Sebbene la misurazione sperimentale degli spostamenti possa essere più complessa, dal punto di vista delle simulazioni, questa scelta si rivela significativamente più efficiente. In letteratura, le frequenze

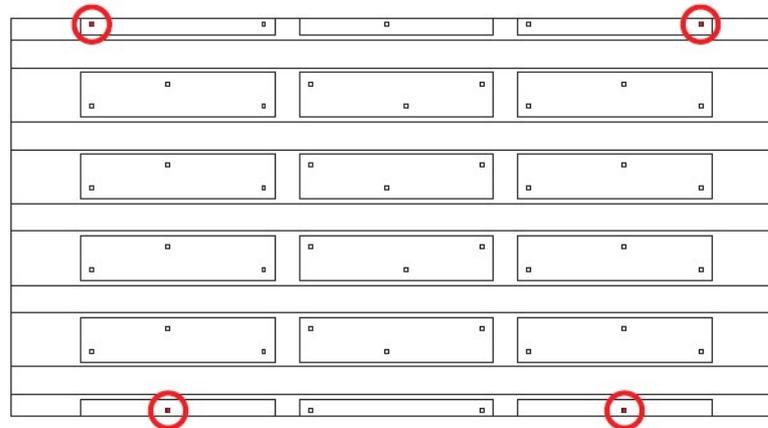
adottate per la misura degli spostamenti, in genere sono dell'ordine delle decine o centinaia di kHz. Per esempio, in [23] le frequenze di campionamento sono passate da 20kHz a 500 kHz; mentre in [31] e [2], hanno ottenuto buoni risultati con la frequenza di campionamento di 200kHz.



**Figura 5.5:** Raggruppamento delle coppie di sensori basato sui diversi livelli di blocchi costruttivi (*Coupon, Element e Sub-Component*) [9].

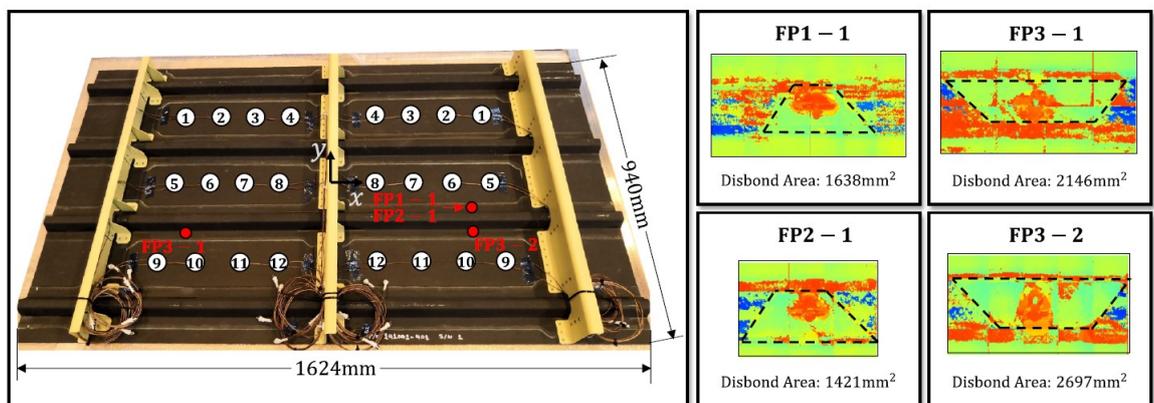
In condizioni reali, per via delle ridotte dimensioni dei sensori, risulta trascurabile la variazione delle misure richieste sull'interfaccia del sensore, tanto da corrispondere al valore medio [34]. Per cui l'inserimento di sensori modellati come solidi in Abaqus, comporterebbe solo una diminuzione dello *stable time increment*. Incrementando di conseguenza il tempo necessario alla simulazione, senza garantire ulteriori benefici. Risulta, per cui, appropriato simulare il comportamento dei sensori, estraendo direttamente le variabili interessate solo nelle posizioni dei nodi interessati.

Alla luce di ciò, nell'attuale modello è stata adottata una frequenza di campionamento di 200 kHz per la misura degli spostamenti nei nodi in cui sono presenti i sensori. Oltre alla scelta della tipologia e frequenza di campionamento dei sensori adottati, è necessario valutare la loro disposizione. Devono coprire omogeneamente l'intera superficie in cui si verificano gli impatti. Nel caso di piastre di grandi dimensioni in cui sono presenti numerosi sensori, risulta opportuno dividere il pannello in più sotto-reti sovrapposte (Fig. 5.5). In tal modo ciascuna sotto-rete presenta un numero limitato di sensori, garantendo una migliore caratterizzazione degli impatti [9].

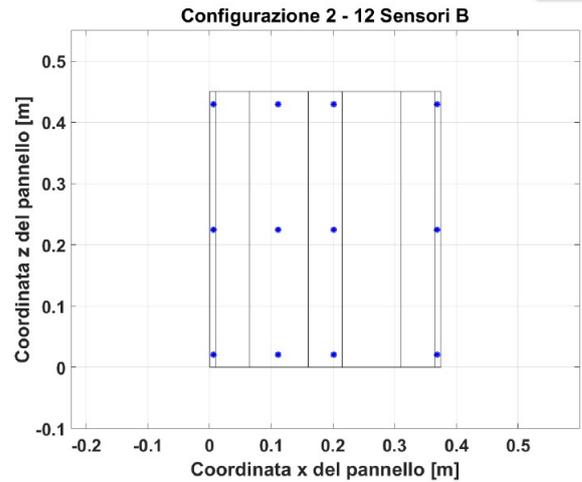


**Figura 5.6:** Esempio di migliori 4 sensori risultati dagli algoritmi genetici in [33].

Una distribuzione ottimale inoltre, garantirebbe migliori prestazioni, riducendo il numero di sensori necessari. Nell'articolo [33], gli autori propongono un metodo di ottimizzazione, per la posizione e il numero ideale di sensori, basata su algoritmi genetici. Tale processo di ottimizzazione, ha lo scopo di trovare la configurazione di sensori che minimizza l'errore associato alle predizioni delle reti. In [1], invece, l'autore determina la disposizione ottimale dei sensori utilizzando i valori dell'errore e del *Mean Squared Error* (MSE). I dati raccolti da 30 nodi (rappresentanti i sensori), hanno garantito come combinazione migliore, quella rappresentata in Figura 5.8, con 12 sensori.



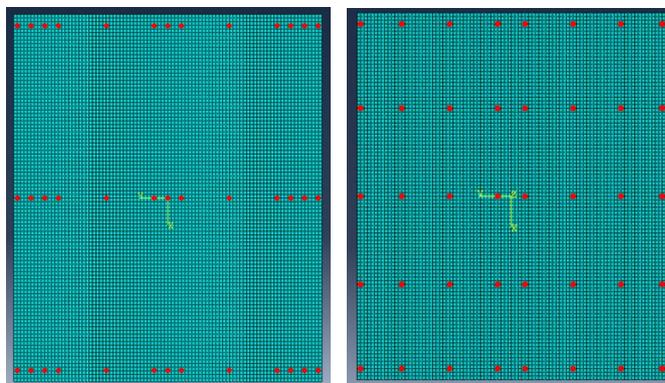
**Figura 5.7:** Rappresentazione della posizione degli impatti e disposizione dei sensori in [10].



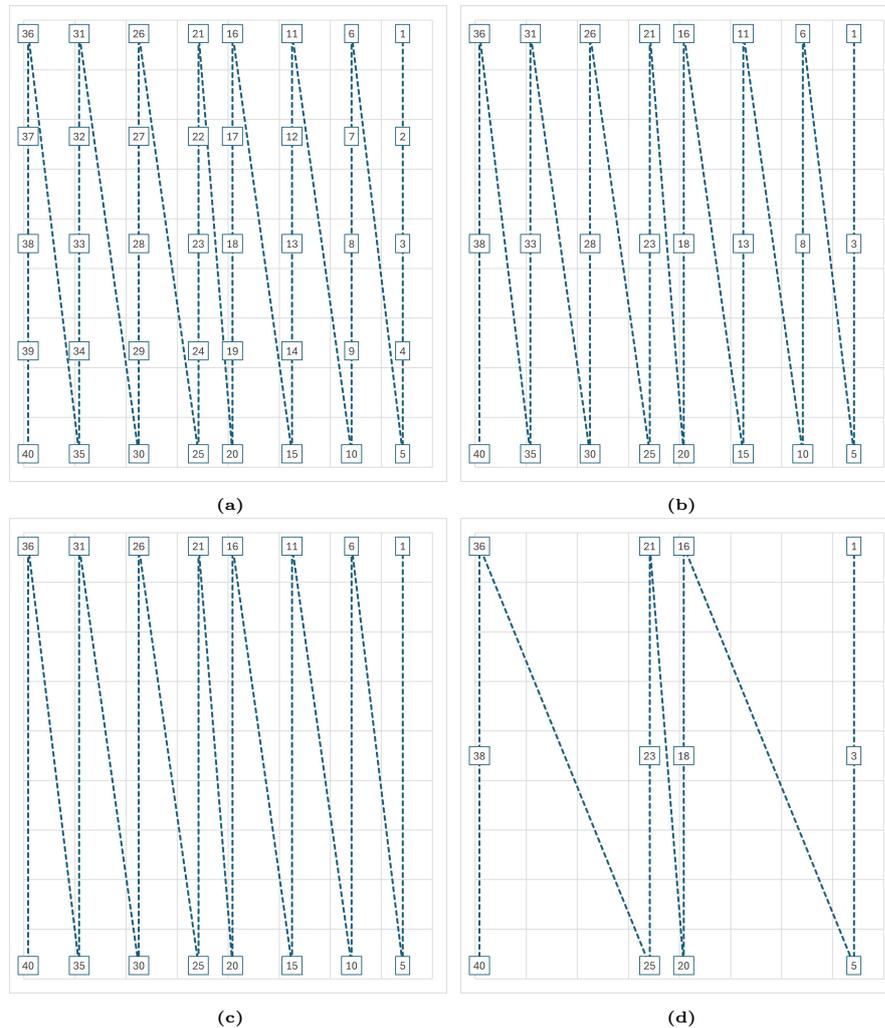
**Figura 5.8:** Configurazione ottimale dei sensori di posizione in Cappellin [1].

Nel modello attuale, sono stati definiti 40 nodi preposti allo scopo di sensori. Sono distribuiti equamente, coprendo tutta la superficie in cui avvengono gli impatti. La loro disposizione comprende sia le zone sovrastanti gli irrigidimenti che le zone comprese tra un irrigidimento e l'altro. Tale scelta è motivata dal fatto che negli articoli pubblicati, la distribuzione dei sensori avviene, o nei pressi degli irrigidimenti, o nelle aree del pannello fra un irrigidimento e l'altro [10] (come mostrato nella Figura 5.7). Alcune posizioni, riprendono quelle della configurazione ottimale riscontrata in [2]. Tuttavia, sono state inserite altre 2 righe, da 8 sensori ciascuna, con lo scopo di avere maggiori dati nella zona centrale.

A partire dai 40 sensori definiti in Abaqus, rappresentati in Figura 5.10, sono state valutate 4 configurazioni, una con tutti e i 40 sensori, una da 24 e le ultime due rispettivamente da 16 e 12.



**Figura 5.9:** Configurazione dei sensori per la raccolta dati: a) Modello di Giacomini [2] b) Modello nuovo.



**Figura 5.10:** Disposizione dei sensori numerati. La linea tratteggiata indica l'ordine di numerazione. a) configurazione adottata da 40 sensori, b) quella da 24 c) configurazione da 16 d) configurazione da 12.

## 5.4 Mesh

Il nuovo modello si differenzia principalmente per l'assenza di modelli di danneggiamento dei materiali, in quanto è utile valutare preliminarmente se per gli impatti inclinati è possibile predire la forza e gli angoli di impatto mediante un approccio basato su tecniche di machine learning. L'inserimento dei criteri di rottura complica eccessivamente il modello, aumentando il costo computazionale e il tempo di calcolo per le numerose simulazioni. Per cui, le superfici coesive presenti nel modello "Fine" sono state sostituite con dei *constrains* di tipo *tie*: questi risultano ideali per unire superfici con *mesh* differenti, in quanto garantiscono una equivalenza negli spostamenti. Prima di procedere alle simulazioni

è stato validato il nuovo modello, Semplificato, effettuando un confronto con il modello Fine (i relativi dati sono riassunti in Tabella 5.2). Il modello Fine rappresenta una buona approssimazione del caso reale, presenta infatti una mesh molto fitta che garantisce un'ottima precisione, e le caratteristiche di rottura tra i componenti incollati. Attraverso questo confronto è possibile garantire che i dati raccolti per l'addestramento delle reti, siano coerenti con la realtà.

Parte	Tipo elementi	Modello Fine	Modello Semplificato
Pannello	SC8R	18750	9000
Irrigidimento	SC8R	12600	5390
Pannello	COH3D8	6750	NO
Irrigidimento	COH3D8	1800	NO
Impattatore	R3D4	390	390
Impattatore	R3D3	30	30

**Tabella 5.2:** Numero di elementi presenti nelle parti che compongono il modello

Gli irrigidimenti e il pannello presentano elementi di tipo *shell* SC8R *linear hexahedral elements*, indicati generalmente per solidi con spessori ridotti. Il modello Semplificato risulta avere 9000 elementi, mentre gli irrigidimenti presentano 5390 elementi ciascuno, composti nello specifico da 2320 elementi per ciascuna trave a "C" e 750 elementi alla base di ogni irrigidimento. Il modello Fine presenta 18750 elementi per il pannello, mentre le travi a "C" presentano 5100 elementi e alla base dell'irrigidimento sono presenti 2400 elementi.

Solo nel modello Fine sono presenti, elementi coesivi di tipo *linear hexahedral elements* COH3D8, da 8 nodi. Infatti, in questo modello si tiene in considerazione la presenza dell'adesivo, fra il pannello e gli irrigidimenti, e all'interno degli irrigidimenti stessi. In particolare fra le 2 travi a "C" che li compongono e alla base di ciascuna trave.

Per l'impattatore di entrambi i modelli sono stati utilizzati 390 elementi di tipo *linear quadrilateral elements* R3D4 e 30 *linear triangular elements* R3D3. Questi elementi risultano adatti per descrivere corpi rigidi, infatti il corpo impattante viene considerato indeformabile, e utilizzano rispettivamente 3 e 4 nodi.

## 5.5 Steps della simulazione

Per inizializzare i vincoli ed imporre le condizioni necessarie alla simulazione, in Abaqus è necessario indicare gli *steps*. Nello *step Initial* vengono inizializzati i vincoli di incastro, i contatti tra le parti, e i *constraints*. Tali vincoli vengono

poi propagati negli *steps* successivi. Sono stati adottati *constraints* di tipo *tie* per unire gli irrigidimenti, i materiali coesivi e il piano del pannello assieme; in quanto tali *constraints* risultano particolarmente adatti ad unire parti con mesh di dimensioni diverse [2]. Sempre nello step iniziale si introduce il contatto di tipo generale (esplicito), tra tutte le parti. Infatti i corpi possono toccarsi senza compenetrare, scambiandosi di conseguenza forze di contatto. Dato che questo tipo di contatto non tiene conto delle forze di attrito, è necessario introdurre l'attrito tangenziale separatamente, con un coefficiente di 0.3.

Una volta imposte le condizioni iniziali è necessario imporre la velocità al corpo impattante. Ciò avviene nello *step Velocity*, questo *step* è di tipo dinamico-esplicito ed è di durata pari a  $0.01ms$ . Si applica al reference point, associato all'impattatore, una velocità in direzione Z. Successivamente sarà possibile modificare attraverso matlab i file di input di Abaqus in modo tale da cambiare sia la coordinata di impatto, che l'intensità e la direzione della velocità. Questa condizione, a differenza di quella iniziale, non si propaga nello *step* successivo; in modo tale da simulare coerentemente un corpo in caduta.

Infine nell'ultimo *step*, *Gravity*, viene inserito l'effetto della gravità ed è quello in cui si osserveranno gli effetti dell'impatto. Per introdurre il carico gravitazionale è stata inserita una accelerazione in direzione Z di  $9.81m/s^2$ , la durata di questo step è stata definita in funzione di alcuni test effettuati. Preliminarmente per questo tipo di modello risulta sufficiente una durata di  $5ms$  per lo svilupparsi della intera forza di contatto fra l'impattatore e il pannello.

Dato che dai test effettuati si evidenziano spostamenti nella zona di impatto di ordini di grandezza paragonabili a quelli della struttura stessa, è necessario selezionare l'opzione *nlgeom*, ossia quella che indica la presenza di grandi spostamenti.

## 5.6 Output

Prima di passare agli output richiesti al simulatore è fondamentale introdurre i concetti di *stable time increment* e frequenza di campionamento per garantire dei risultati validi e accurati. Lo *stable time increment* è un concetto utilizzato nelle simulazioni agli elementi finiti. Si riferisce all'incremento di tempo (time-step) massimo che può essere utilizzato in una simulazione per garantire la sua stabilità. Infatti, se tale intervallo supera lo *stable time increment*, la simulazione potrebbe diventare instabile e produrre risultati non fisici. È possibile calcolare

tale valore attraverso il criterio di Courant-Friedrichs-Lewy (CFL) [41]. Lo *stable time increment* risulta proporzionale al rapporto tra la lunghezza caratteristica del problema e la velocità di propagazione dell'onda nel materiale (Eq. 5.6.1):

$$\Delta t \leq \frac{C \cdot \Delta x}{c} \quad (5.6.1)$$

Dove:  $\Delta t$  è l'intervallo di tempo, o *time step*, adottabile per la simulazione;  $C$  è un coefficiente di sicurezza, tipicamente compreso tra 0 e 1;  $\Delta x$  è la dimensione minima della *mesh*;  $c$  è la velocità del suono nel materiale.

La velocità del suono in un materiale isotropo si calcola mediante la seguente equazione:

$$c = \sqrt{\frac{E}{\rho}} \quad (5.6.2)$$

Dove:  $c$  è la velocità del suono;  $E$  è il modulo di Young;  $\rho$  è la densità del materiale.

È possibile stimare un  $\Delta t = 1.7 \cdot 10^{-7} s$  considerando il massimo modulo di Young e la minima lunghezza caratteristica, che è ampiamente al di sopra di  $8 \cdot 10^{-8} s$  usato come *stable time increment* proposto in automatico da Abaqus per questo modello.

La frequenza di campionamento indica il numero di campioni necessari per ricostruire accuratamente un segnale. Misurata in Hz, essa rappresenta il numero di misurazioni di un segnale effettuate in un secondo. Questo è fondamentale poiché, per acquisire dati associati a un segnale continuo, come potrebbe essere per la misura della accelerazione o spostamento di un sensore, è necessario discretizzare il segnale affinché possa essere elaborato digitalmente. Il processo di campionamento consiste nel discretizzare la variabile tempo e, per ogni istante discreto, registrare la corrispondente ampiezza del segnale (la nostra misura di riferimento). La scelta della frequenza di campionamento è importante per garantire una corretta ricostruzione del segnale. Secondo il teorema del campionamento di Nyquist-Shannon, per campionare un segnale senza perdita di informazioni, la frequenza di campionamento  $f_c$  deve essere almeno il doppio della massima frequenza  $f$  presente nel segnale (Eq. 5.6.3).

$$f_c = 2f \quad (5.6.3)$$

Per questo motivo, prima di procedere alla scelta della frequenza di cam-

pionamento dei segnali dei sensori, è stata effettuata una simulazione con una frequenza di campionamento molto elevata, pari a  $20000kHz$  per poter verificare l'entità delle frequenze dei singoli segnali. Da questa analisi si evidenzia che una frequenza di campionamento di  $200kHz$  risulta adeguata per le informazioni degli spostamenti e delle velocità (in accordo con le esperienze di [1] e [2]). Le informazioni sulle accelerazione invece, necessitano di frequenze di campionamento più alte, non compatibili con le capacità di calcolo e la memoria a disposizione. Per questo motivo è stato deciso di non usare queste informazioni.

Al software Abaqus sono stati richiesti i seguenti output:

- L'evoluzione della forza di contatto in funzione del tempo (CTFM ossia *Total force due to contact pressure and frictional stress*). Per questi dati è stata effettuata una operazione di filtraggio successiva alle simulazioni mediante il software matlab, in quanto questo permette di avere un maggiore controllo sulla qualità dei dati.
- Le informazioni relative agli spostamenti (U), alle velocità (V) relative ai nodi corrispondenti alle posizioni dei sensori.

È da sottolineare che in una situazione sperimentale, sarebbe più idoneo usare le accelerazioni o altre grandezza più semplici da misurare con sensori commerciali. Tuttavia, nel solutore FEM, l'estrazione dei dati relativi alla velocità e agli spostamenti risulta più conveniente in termini di risorse computazionali. Ad esempio, utilizzando una elevata frequenza di campionamento nel modello "Fine", pari a  $20000kHz$ , sono state impiegate 9 ore di calcolo e sono stati generati  $90GB$  di file per i valori delle accelerazione, velocità e spostamenti relativi ai sensori. Inoltre, come osservato in [27], le reti neurali convoluzionali forniscono in genere predizioni più accurate utilizzando gli spostamenti anziché le accelerazioni.

## 5.7 Verifica del modello

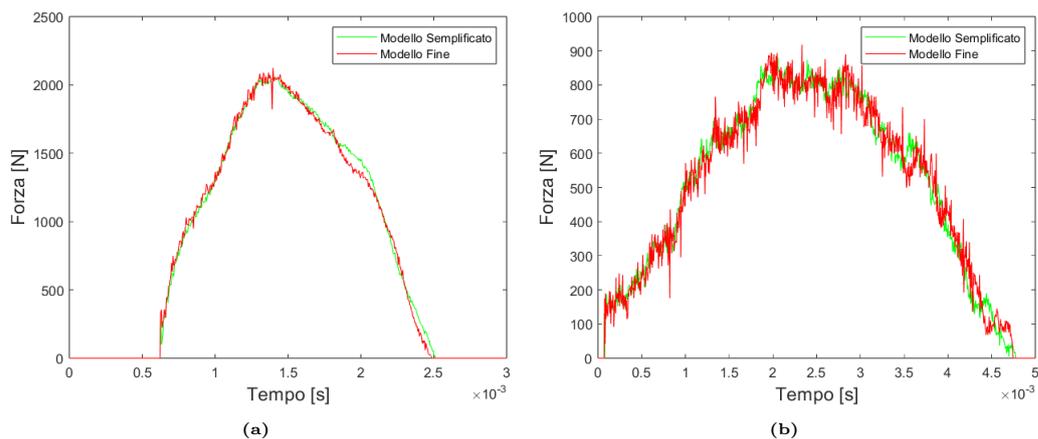
La verifica e validazione dell'attuale modello è basata sul confronto tra il profilo della forza di impatto del modello "Semplificato" con quello del modello "Fine", in quanto il modello "Fine", riprende le principali caratteristiche della struttura validata sperimentalmente in [31]. La pubblicazione di Faggiani e Falzon [31] consisteva nel simulare fenomeni di delaminazione di un pannello irrigidito attraverso l'analisi FEM e il successivo confronto con i dati ottenuti sperimentalmente per un pannello reale. La medesima struttura è stata ripresa nelle tesi di laurea [1]

e [2] con delle opportune semplificazioni, al fine di addestrare delle reti neurali per la predizione delle caratteristiche legate all'impatto (ad esempio forza e posizione dell'impatto).

L'uso di diversi tipi di modelli ha evidenziato le differenze nei tempi di simulazione. Utilizzando i calcolatori del polo di calcolo dell'università, il modello "Fine", usato per la validazione, ha richiesto 117 minuti per simulazione; a differenza del modello adottato in [2], che richiede solo 37 minuti. Le semplificazioni introdotte nel modello "Semplificato" hanno permesso un ulteriore risparmio di tempo, riducendo il tempo di simulazione a soli 17 minuti. Questo rende il modello compatibile con i tempi disponibili per le numerose simulazioni necessarie per l'addestramento delle reti. Di conseguenza, è possibile eseguire il doppio delle simulazioni di [2] nello stesso lasso di tempo, ottenendo risultati analoghi.

Riassumendo le caratteristiche dei modelli:

- Modello "Fine": è analogo al modello di [2]. Presenta una mesh molto fitta, e include i modelli di danneggiamento degli incollaggi delle parti, inoltre riprende tutte le principali caratteristiche del modello validato sperimentalmente in [31].
- Modello "Semplificato": i materiali coesivi nelle interfacce vengono eliminati e non si usano i modelli di danneggiamento degli incollaggi.



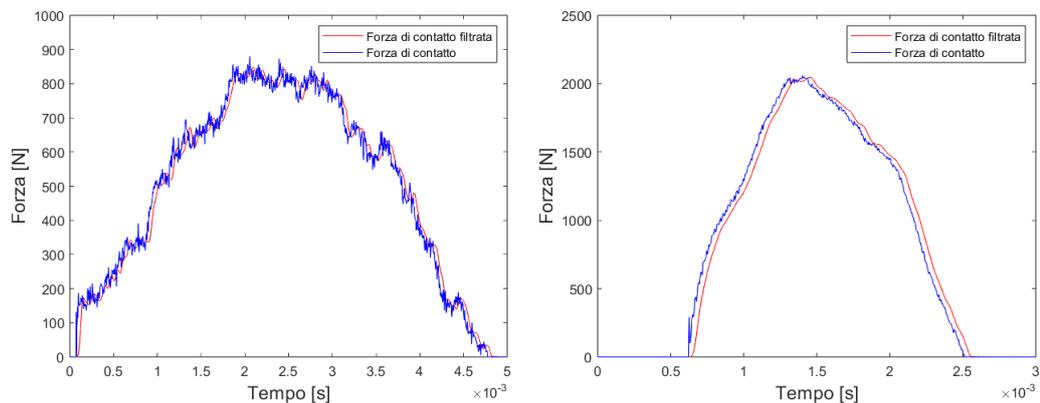
**Figura 5.11:** Esempio di confronto fra modello Semplificato e modello Fine della forza di contatto in a) un impatto perpendicolare in posizione centrale b) in un impatto inclinato in una posizione laterale

Dalle simulazioni effettuate ne risulta che il modello "Semplificato" riesce a modellare correttamente il problema, nonostante le semplificazioni. Si può osservare in Figura 5.11 come il profilo della forza di contatto sia analogo tra i

2 modelli. Tuttavia, nell'impatto inclinato in posizione laterale (figura 5.11b) si nota come sia evidente la necessità di un filtro per ridurre il rumore introdotto dalla simulazione del nuovo modello.

### 5.7.1 Applicazione del filtro

Con la riduzione della mesh compaiono diverse perturbazioni nel profilo della forza. Per ovviare a tale problema, tramite il software Matlab è stato applicato un filtro ai dati relativi alla forza di contatto. La scelta ricade su un comune filtro passa-basso, di tipo Butterworth, questo infatti è progettato per avere una risposta in frequenza il più piatta possibile nella banda di frequenza di passaggio. Filtri di questo tipo, sono caratterizzati da due parametri principali, la frequenza di *cutoff* e l'ordine del filtro [61]. La frequenza di taglio, o *cutoff*, corrisponde alla frequenza, al di sopra della quale il filtro *Butterworth* inizia ad attenuare il segnale; mentre al di sotto di tale frequenza il segnale passa senza attenuazioni significative. L'ordine del filtro invece, indica il numero di poli nel sistema. Gli ordini superiori indicano generalmente una maggiore selettività del filtro, cioè la capacità di attenuare le frequenze al di fuori della banda di passaggio in modo più rapido e con un maggiore controllo della transizione tra la banda di passaggio e quella di attenuazione. Risulta efficace per queste simulazioni un filtro *Butterworth* di ordine 6 con una frequenza di taglio di 0.15.



**Figura 5.12:** Esempio di confronto per il modello Semplificato con e senza filtro per la forza di contatto: a) in un impatto inclinato in una posizione laterale del pannello b) in un impatto perpendicolare in posizione centrale

## 5.8 Impatti inclinati in posizione centrale

Al fine di ottenere dei dati preliminari per l'allenamento delle reti neurali, è stato effettuato un set di simulazioni, che presentavano impatti inclinati solo al centro del pannello. Data la riduzione della complessità, sono state necessarie solo 200 simulazioni impiegando circa 70 ore di calcolo. Per modificare le caratteristiche specifiche di ciascuna simulazione, è stato utilizzato uno script Matlab. Tale script modifica il file di input ".inp" di Abaqus, affinché per ogni simulazione ci fosse un diverso angolo casuale di impatto e differente massa e velocità del proiettile. In particolare è stato deciso di usare 2 angoli (figura 5.13): l'angolo  $\phi$  fra l'asse del proiettile e il piano del pannello, compreso fra  $30^\circ$  e  $90^\circ$ , e l'angolo  $\theta$  nel piano del pannello compreso tra  $0^\circ$  e  $360^\circ$  allineato con l'asse  $z$ .

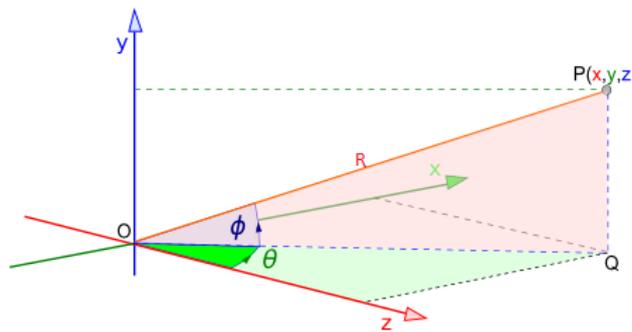


Figura 5.13: Angoli usati.

Le caratteristiche degli impatti indagati sono (Fig. 5.14):

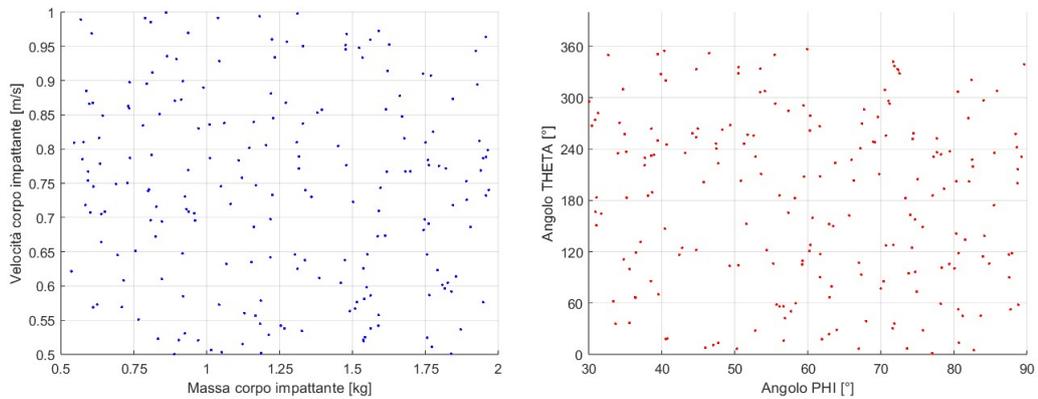
- Massa compresa tra 1 e 2kg.
- Velocità compresa tra 1 e 0.5m/s.
- Angolo  $\theta$  compreso tra  $0^\circ$  e  $360^\circ$ .
- Angolo  $\phi$  compreso tra  $30^\circ$  e  $90^\circ$ .

Prima di procedere alle simulazioni 200 simulazioni in posizione centrale, sono state effettuate una decina di simulazioni di prova, utili ad identificare le peculiarità degli urti inclinati. Sono stati sviluppati 2 gruppi da 5 simulazioni in posizione centrale. L'obiettivo è di osservare la variazioni degli output quali, forza di impatto e misure dei sensori al variare dell'angolo  $\phi$ . Il primo gruppo

comprende cinque simulazioni che analizzano il caso delle condizioni massime, ossia quelle che dovrebbero garantire la massima forza di contatto, quindi i valori di massa e velocità più elevati fra quelli considerati. Il secondo gruppo invece, analizza le condizioni minime, ossia quelle che analizzano la forza di impatto per la minima massa e velocità del corpo impattante. I dati usati sono riassunti in tabella 5.3, e gli angoli  $\phi$  osservati sono compresi fra  $30^\circ$  e  $90^\circ$ .

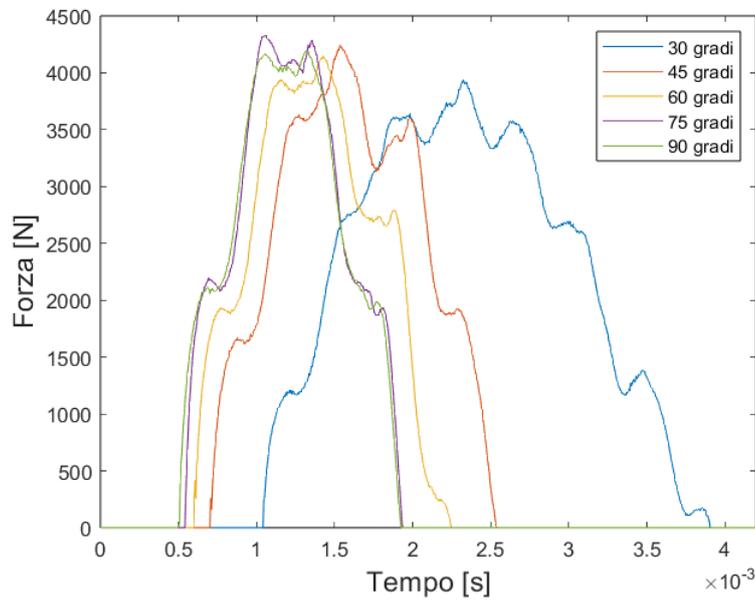
	$\theta_0$	Massa (kg)	Velocità (m/s)
Condizioni massime	$0^\circ$	2	1
Condizioni minime	$0^\circ$	1	0.5

**Tabella 5.3:** Condizioni minime e massime in un impatto centrale.



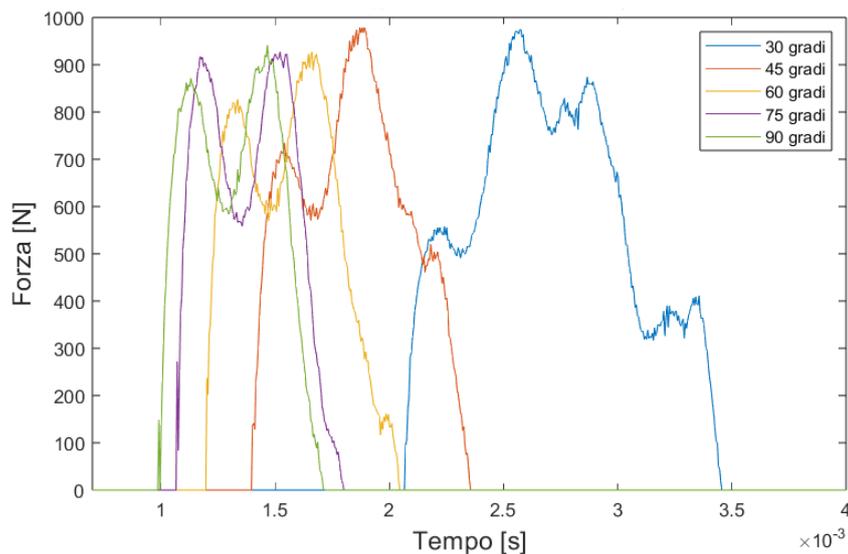
**Figura 5.14:** Distribuzione osservate nelle 200 simulazioni effettuate di: a) masse e velocità di impatto b) Distribuzione degli angoli  $\phi$  e  $\theta$

Dai test effettuati in condizioni massime (massa  $2\text{kg}$ , velocità  $1\text{m/s}$ ), rappresentate in Figura 5.15. Si osserva che alla diminuzione dell'angolo fra l'asse del proiettile e il pannello (l'angolo  $\phi$ ), il profilo della forza di contatto nel tempo tende a spostarsi verso destra e appiattirsi. Si evidenzia inoltre, che il picco di forza massimo si ha per impatti perpendicolari o quasi ( $90^\circ$  e  $75^\circ$ ).



**Figura 5.15:** Forza di contatto in funzione dell'angolo di impatto  $\phi$  a parità di condizioni iniziali-massime: massa  $2kg$  e velocità  $1m/s$  e angolo  $\theta$  pari a  $0^\circ$ .

Dai test effettuati in condizioni minime, rappresentate in Figura 5.16, si evince che il tempo in cui si sviluppa la forza di contatto, aumenta al diminuire dell'angolo  $\phi$ , in modo analogo al caso precedente. Mentre il picco di forza di contatto non presenta evidenti variazioni al variare di  $\phi$ .



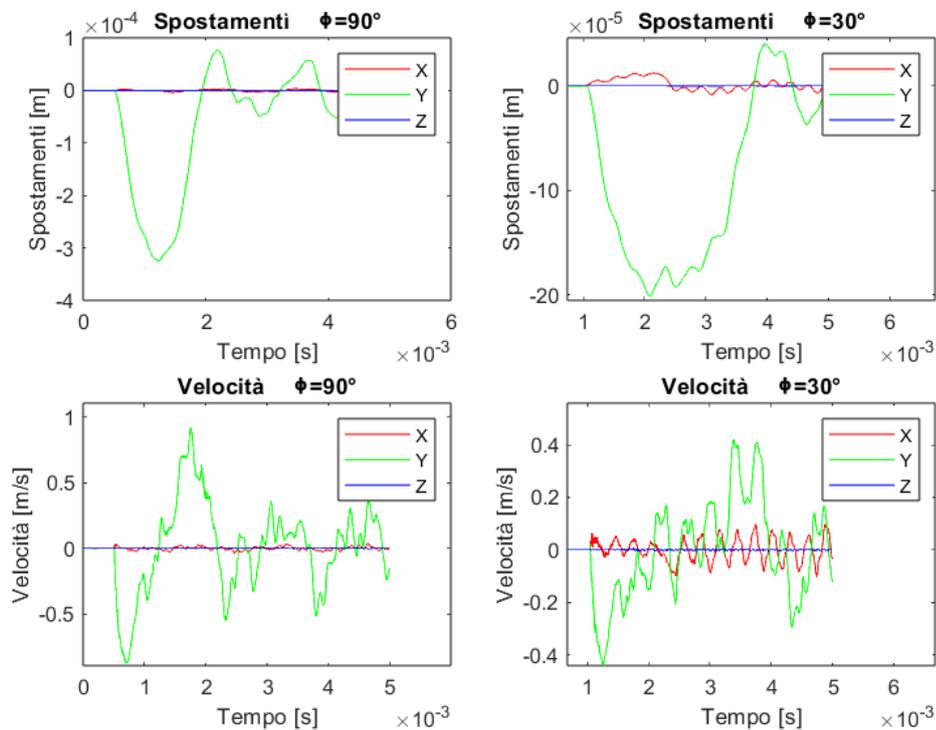
**Figura 5.16:** Forza di contatto in funzione dell'angolo di impatto  $\phi$  a parità di condizioni iniziali minime: massa  $0.5kg$  e velocità  $0.5m/s$  e angolo  $\theta$  pari a  $0^\circ$ .

Confrontando i 2 grafici, figure 5.15 e 5.16, si evince che oltre a un maggiore valore della forza massima per le condizioni massime, anche la durata della forza

di contatto è maggiore, ad esempio per un urto perpendicolare nelle condizioni massime dura  $1.4ms$  mentre in quelle minime  $0.7ms$ . Nel caso di  $\phi$  pari a  $30^\circ$ , si ha una durata di  $2.9ms$  per le condizioni massime e  $1.3ms$  per quelle minime. È da tenere conto durante l'elaborazione dei dati, che l'impatto non ha inizio allo stesso momento per ciascun angolo di impatto  $\phi$ . Ciò è causato dalla geometria del modello, in quanto negli impatti inclinati, l'impattatore percorre una maggiore distanza rispetto a quelli perpendicolari prima di impattare sul pannello.

In Figura 5.17 sono state confrontate le misure di spostamento e velocità registrate da uno dei sensori centrali, per un impatto in condizioni massime, per  $\phi$  pari a  $90^\circ$  e  $30^\circ$  e con  $\theta$  pari a  $0^\circ$ . Si può osservare che:

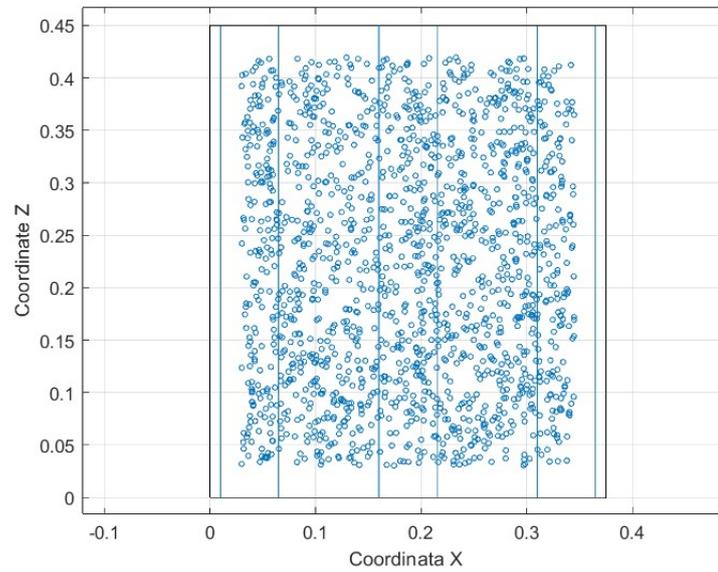
- Per gli impatti perpendicolari, le misurazioni lungo gli assi nel piano (X e Z) sono trascurabili in confronto alle misurazioni lungo la verticale (Y).
- Per gli impatti inclinati, le misure di spostamenti e velocità, presentano una componente non trascurabile lungo l'asse X, e trascurabile per l'asse Z in quanto l'angolo  $\theta$  adottato è nullo.



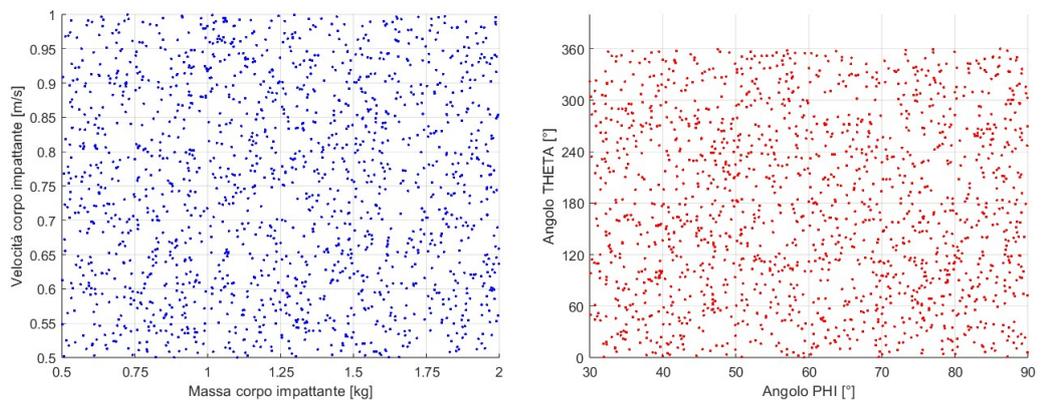
**Figura 5.17:** Confronto fra le misure del sensore centrale di spostamento/velocità/accelerazioni nel caso di  $\phi$  pari a  $90$  e  $30$  (in un impatto centrale a parità di condizioni iniziali massime: massa  $2kg$  e velocità  $1m/s$  e angolo  $\theta$  pari a  $0$ ).

## 5.9 Impatti nel piano

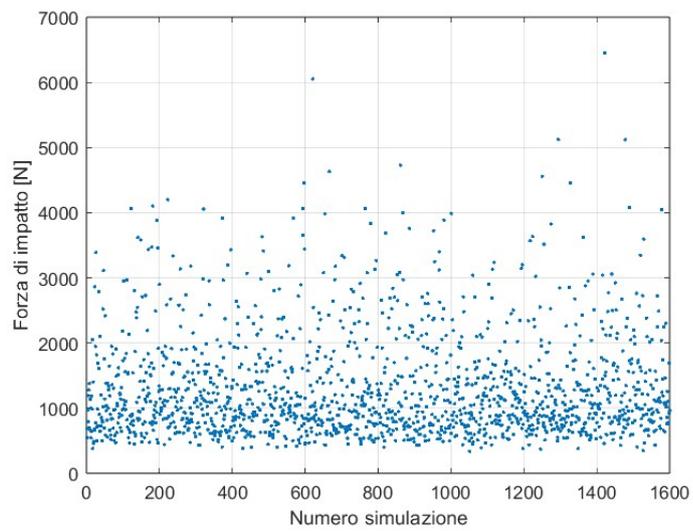
Per effettuare gli impatti su tutta la superficie del pannello, è stata designata un'area sufficientemente ampia. L'area di impatto comprende l'intero piano fino a  $30mm$  dai bordi, garantendo che gli impatti avvengano in zone coperte dai sensori. Sono state effettuate 1600 simulazioni per l'addestramento delle reti, con un tempo totale di simulazione di 23 giorni. Proprio per questo motivo, l'uso di modelli più complessi rispetto a quello "Semplificato" non sarebbero stati adatti, poiché avrebbe ulteriormente aumentato il tempo di calcolo. La scelta di effettuare così tante simulazioni, decisamente in numero maggiore rispetto lavoro precedente [2], si rispecchia nella necessità di avere dei set più ampi per apprendere adeguatamente caratteristiche più complesse dai dati. Infatti, l'introduzione di gradi di libertà aggiuntivi, come gli angoli di impatto, comporta una notevole difficoltà per le reti nel predire correttamente il problema. Lo scarso successo di [2] nel caratterizzare gli impatti inclinati si può riscontrare molto probabilmente o nel numero limitato di simulazioni o nella semplicità delle reti utilizzate. L'utilizzo di reti più complesse, quindi in grado di riconoscere pattern più complessi, necessita di set più grandi, e per questo motivo 1600 simulazioni sono risultate un numero adeguato al problema. Le simulazioni prese in considerazione presentano posizioni casuali indicate in Figura 5.18, e con masse, velocità e angoli associati all'impattatore negli stessi range discussi nella sezione precedente. È possibile osservare un'equa distribuzione dei valori presi come riferimento nelle figure 5.18 e 5.19. I picchi di forza di contatto ottenuti dalle simulazioni, si distribuiscono in un range che va da  $339N$  a  $6450N$  rappresentato in Figura 5.20.



**Figura 5.18:** Posizioni osservate nei 1600 impatti effettuati in tutto il piano



**Figura 5.19:** Distribuzione osservate nelle 1600 simulazioni effettuate di: a) masse e velocità di impatto b) Distribuzione degli angoli  $\phi$  e  $\theta$  di impatto osservate nelle 1600 simulazioni effettuate



**Figura 5.20:** Forze di impatto osservate nelle 1600 simulazioni effettuate

# Capitolo 6

## Reti Neurali

Date le caratteristiche non lineari del modello, come i grandi spostamenti, e la presenza dell'attrito durante gli impatti, questo tipo di problema risulta particolarmente adatto ad essere risolto mediante un approccio basato sul machine learning. È stato scelto di analizzare le capacità predittive di 2 tipi di reti neurali, in particolare le reti neurali artificiali e le reti neurali convoluzionali.

### 6.1 Definizione Errori e Metriche

Per definire le performance delle reti sono stati adottati gli errori medi e il *Root Mean Squared Error* (RMSE). L'errore medio (Eq. 6.1.4), calcolato mediante la media aritmetica, identifica se la rete riesce a distribuire equamente le predizioni attorno ai valori reali. L'RMSE (Eq. 6.1.6), invece, è particolarmente utile per valutare le previsioni nei problemi di regressione. Fornisce una misura della distanza media tra i valori previsti e quelli reali. Un RMSE minore, per cui, indica una maggiore precisione del modello.

Un'ulteriore metrica valutata solo per le forze di impatto, è la deviazione standard dell'errore relativo (o  $\sigma$ , Eq. 6.1.7), essa misura quanto gli errori relativi in un insieme di dati si discostino dalla media, fornendo un'indicazione della variabilità dei dati.

Errore Assoluto:

$$Errore = Y_{predetto} - Y_{reale} \quad (6.1.1)$$

Errore relativo:

$$Errore_{rel} = \frac{Y_{predetto} - Y_{reale}}{Y_{reale}} \quad (6.1.2)$$

Errore percentuale:

$$Errore_{\%} = Errore_{rel} \cdot 100\% \quad (6.1.3)$$

Errore Medio:

$$Errore_{medio} = \frac{\sum_{n=1}^N (Errore)_n}{N} \quad (6.1.4)$$

Mean Squared Error:

$$MSE = \frac{\sum_{n=1}^N (Errore)_n^2}{N} \quad (6.1.5)$$

Root Mean Squared Error:

$$RMSE = \sqrt{\frac{\sum_{n=1}^N (Errore)_n^2}{N}} \quad (6.1.6)$$

Deviazione Standard dell'errore relativo:

$$\sigma = \sqrt{\frac{1}{N} \sum_{n=1}^N \left( Errore_{rel} - \sum_{n=1}^N \left( \frac{Errore_{rel}}{N} \right) \right)_n^2} \quad (6.1.7)$$

Mentre gli errori medi e l'RMSE risultano particolarmente adatti a tutti i problemi indagati, l'uso di errori percentuali medi e della deviazione standard degli errori relativi era meno indicato per la valutazione dell'accuratezza degli angoli. Questo perché l'angolo al denominatore avrebbe generato troppa variabilità negli errori percentuali, in particolare per angoli prossimi allo zero l'errore percentuale poteva assumere valori significativi. Data la periodicità dell'angolo  $\theta$ , gli errori sono stati calcolati considerando la differenza nella direzione in cui il valore risulta minore, in modo tale da avere l'errore assoluto sempre compreso fra  $-180^\circ$  e  $180^\circ$ .

## 6.2 Reti Neurali Artificiali

Sono state adottate reti neurali artificiali di tipo *feed forward*, il cui addestramento avviene mediante algoritmi basati sulla minimizzazione della funzione di perdita, o *loss function*. A tale scopo, il gradiente della funzione di perdita viene calcolato attraverso un algoritmo di *back-propagation* utilizzando il modello di *Levenberg-Marquardt*. Questo metodo è noto per le sue elevate prestazioni e per una velocità di convergenza generalmente superiore rispetto ad altri, in quanto

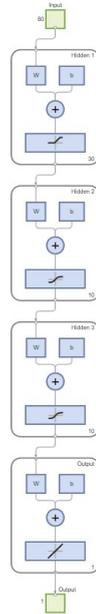
nel calcolo del gradiente si omette il calcolo della Hessiana, riducendo così il peso computazionale. L'addestramento della rete procede ad ogni iterazione variando i pesi e i bias dei neuroni nella direzione in cui il gradiente risulta negativo, valutandone le prestazioni mediante l'errore quadratico medio (MSE).

Le reti neurali artificiali utilizzate nei capitoli seguenti hanno una struttura a tre layer nascosti (o *hidden layers*), come rappresentato in Figura 6.1. Le reti adottate si differenziano principalmente per il numero di neuroni in ciascun layer. Per determinare il numero ottimale di neuroni, è stato adottato un approccio iterativo. Sono stati effettuati numerosi addestramenti, variando iterativamente il numero di neuroni per ciascun layer. Dopo ogni addestramento, uno script valuta le reti addestrate su un set di input diverso da quello utilizzato per l'addestramento. Confrontando i risultati ottenuti dalle reti su questo nuovo set di dati con i valori reali da predire, sono stati calcolati errori percentuali, medi, massimi, RMSE e deviazione standard degli errori relativi. Successivamente, tali parametri sono stati utilizzati come criterio per determinare la configurazione ottimale della rete.

Le funzioni di trasferimento applicate a ciascun layer sono state scelte in base a prove empiriche effettuate. È stata utilizzata la funzione Satlin per il primo layer nascosto, mentre i due layer successivi impiegano la funzione di trasferimento Tan-Sigmoid. Quest'ultima funzione, oltre ad aver garantito minori errori, è nota in letteratura per il suo migliore adattamento ai problemi di tipo non lineare [1]. Infine, il layer di output adotta una funzione lineare.

La *loss function* viene valutata tramite l'errore quadratico medio o MSE (*Mean Squared Error*). La MSE, comunemente usata come *loss function* nei problemi di regressione, calcola la media dei quadrati degli errori tra i valori predetti e quelli reali. Durante l'addestramento, la rete adatta i pesi e i bias ad ogni iterazione, nella direzione in cui il gradiente della *loss function* è negativo, al fine di minimizzare l'errore delle predizioni.

Si è osservato dai numerosi addestramenti effettuati, che la problematica più presente, non era l'*overfitting*, o la presenza di minimi locali, ma bensì la comparsa di *plateau* nella funzione di errore. I plateau si manifestano come una stagnazione della curva di errore, impedendo di raggiungere migliori performance. Tuttavia, come descritto in [54], lo scopo della rete non è quello di trovare un minimo globale, bensì quello di trovare una approssimazione del problema che presenti un errore, tale che garantisca alla rete una buona capacità di generalizzazione. Per cui la loro comparsa risulta inevitabile, ma lo scopo è quello di far sì che si



**Figura 6.1:** Esempio di struttura di rete usata per predire la forza di impatto.

manifestino a valori di MSE il più bassi possibile, variando l'architettura di rete, o gli input.

### 6.2.1 Scelta degli Input e dei Target

Nel software Matlab per addestrare una rete neurale artificiale è necessario inserire tutti gli input in forma di una unica matrice, dove ogni riga fa riferimento a una singola simulazione effettuata; i target di riferimento, invece, vengono inseriti come vettore.

Sono stati testati 2 tipi di input per le reti neurali, una matrice  $A$  che contiene solo le ampiezze massime misurate da ciascun sensore (Eq. 6.2.1), e una matrice  $t|A$ , che contiene anche l'informazione inerente all'istante di tempo in cui è stato misurato il segnale dell'impatto dal sensore (Eq. 6.2.2). I tempi indicati nella matrice, vengono registrati a partire del primo segnale misurato da un qualsiasi sensore presente sulla piastra. Gli altri sensori, in modo analogo, indicano il tempo di ritardo rispetto a tale segnale. La matrice  $A$  è composta da 200 righe e 40 colonne nel caso degli impatti centrali; mentre è composta da 1600 righe e 40 colonne per gli impatti sul piano.

$$[A] = \begin{bmatrix} A_{1,1} & A_{1,2} & \dots n \text{ sensori} \dots & A_{1,n} \\ A_{2,1} & A_{2,2} & \dots & A_{2,n} \\ & & \dots m \text{ simulazioni} \dots & \\ A_{m,1} & A_{m,2} & \dots & A_{m,n} \end{bmatrix} \quad (6.2.1)$$

La matrice  $t|A$  è composta dallo stesso numero di righe della matrice  $A$ , (200 nel caso centrale e 1600 per gli impatti sul piano), ma a differenza di quest'ultima presenta 80 colonne. Il numero di colonne è doppio, perché in questo caso, per ogni simulazione, ogni sensore registra 2 informazioni, l'ampiezza massima e il tempo di arrivo del relativo segnale.

$$[t|A] = \begin{bmatrix} t_{1,1} & \dots n \text{ sensori} \dots & t_{1,n} & A_{1,1} & \dots n \text{ sensori} \dots & A_{1,n} \\ t_{2,1} & \dots & t_{2,n} & A_{2,1} & \dots & A_{2,n} \\ & \dots m \text{ simulazioni} \dots & & & & \\ t_{m,1} & \dots & t_{m,n} & A_{m,1} & \dots & A_{m,n} \end{bmatrix} \quad (6.2.2)$$

Dalle prove preliminari per la stima della forza di impatto con le reti neurali, sono stati valutati gli effetti associati alla variazione del numero di sensori, riducendo così il numero di colonne della matrice di input.

Nel primo caso sono state valutate solo le informazioni degli spostamenti massimi (Eq. 6.2.1) per le 4 configurazioni dei sensori osservate. Per le reti ANN degli impatti nel piano, si ottengono i risultati riassunti in Tabella 6.1 per la ricostruzione della forza di impatto. Si evidenzia che usando 40 sensori, i risultati non sono accettabili, in quanto presentano errore medio percentuale e RMSE troppo elevati. La configurazione più adatta per predire la forza di impatto è risultata essere quella con 24 sensori utilizzando i soli spostamenti massimi, garantendo un RMSE pari a 274.4 N e il minore errore medio percentuale.

Sensori	RMSE [N]	Err. medio [N]	Err. medio %	DevSt
12	505.5	10.9	-7.0	0.31
16	337.1	-26.6	-4.8	0.22
24	274.4	-1.2	-1.3	0.15
40	766.8	-17.8	-30.5	0.72

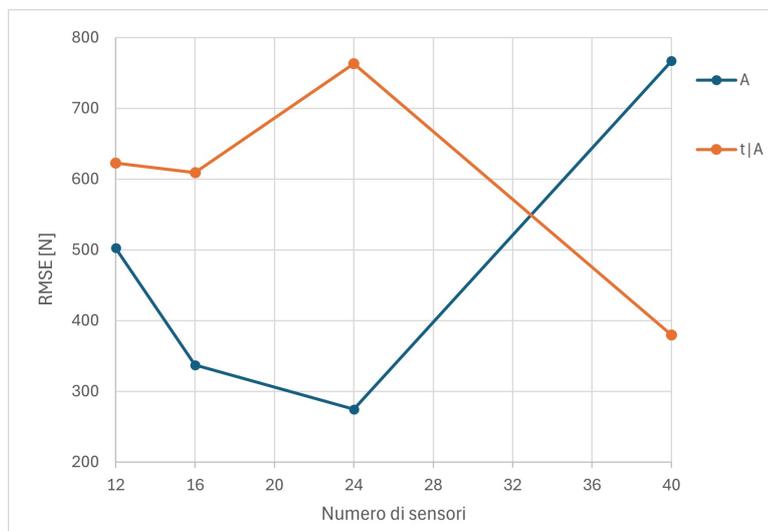
**Tabella 6.1:** Miglioramento delle prestazioni delle ANN al variare di sensori inseriti. Dati in input spostamenti massimi per la stima della forza di impatto con la rete 30-10-10, per gli impatti nel piano.

Valutando invece il caso in cui la matrice di input contiene sia le informazioni del tempo sia lo spostamento massimo (Eq. 6.2.2), si ottengono i risultati mostrati in Tabella 6.2. In questo caso, l'inserimento di ulteriori informazioni, come il tempo di arrivo del segnale ai sensori, peggiora i risultati nei casi con meno sensori. Tuttavia, nel caso di 40 sensori, i risultati sono paragonabili a quelli ottenuti con 16 sensori in Tabella 6.1.

Sensori	RMSE [N]	Err. medio [N]	Err. medio %	DevSt
12	622.8	92.6	-1.6	0.42
16	609.3	-16.5	-13.0	0.49
24	762.8	43.5	-20.0	0.64
40	379.8	9.8	-1.6	0.21

**Tabella 6.2:** Miglioramento delle prestazioni delle ANN al variare di sensori inseriti. Dati in input spostamenti massimi e tempi per la stima della forza di impatto con la rete 30-10-10, per gli impatti nel piano.

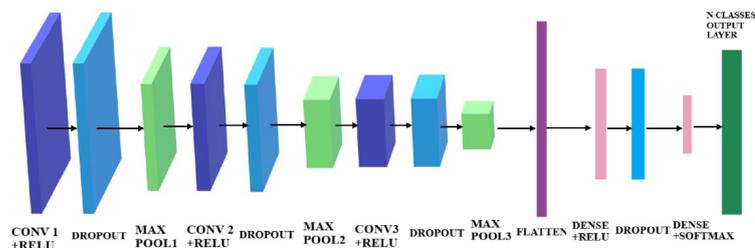
È importante considerare che le reti neurali sono molto dipendenti dai valori iniziali di pesi e bias, per cui i risultati possono variare ripetendo le simulazioni. Per le altre simulazioni, ossia per la predizione degli angoli, è stato valutato l'uso delle matrici contenenti i dati dei 40 sensori di spostamento più il tempo di arrivo dei segnali. Questo perché l'uso dei soli spostamenti ha dato esiti insufficienti per la determinazione degli angoli, generando predizioni stocastiche.



**Figura 6.2:** Andamento delle RMSE nelle ANN al variare del numero di sensori e in base alla scelta della matrice di input.

## 6.3 Reti Neurali Convoluzionali

In letteratura ci sono svariati esempi di come implementare CNN nei casi di impatti su pannelli in materiale composito. Dall'insieme di studi osservati, si evince che in genere le CNN vengono usate principalmente a scopo di classificazione, garantendo generalmente risultati più accurati delle ANN in queste condizioni. Ad esempio, in [22] si raggiunge un'accuratezza fra il 94% e il 100% classificando l'energia di impatto su pannelli compositi in tre livelli, a partire da segnali provenienti da sensori sulla superficie impattata. Generalmente, le reti neurali convoluzionali vengono usate per la classificazione di immagini; tuttavia, in questo lavoro di tesi, è stato esteso il loro uso a problemi di regressione, ottenendo un comportamento analogo alle reti ANN. Le CNN, a differenza delle ANN, hanno il vantaggio di raccogliere più informazioni di input, poiché queste non sono in forma di vettori per ciascuna simulazione, ma bensì immagini o informazioni in forma tabulata. Durante il *training*, in modo analogo alle ANN, adattano i parametri dei vari layer per ottenere un output numerico, in questo caso scalare [52]. Le CNN hanno inoltre la capacità di estrarre dettagli dalla disposizione di tali valori, garantendo in genere capacità predittive migliori. In questo modo si può valutare se tali reti rappresentino un reale vantaggio nel caratterizzare impatti inclinati.



**Figura 6.3:** L'architettura proposta da [22] per la CNN comprende 3 insiemi ripetitivi di strati convoluzionali, dropout, pooling, seguiti da uno strato di appiattimento (Flatten), uno strato denso (Dense), dropout e infine uno strato denso

Il modello proposto nella pubblicazione [22], consiste in una CNN che analizza i dati provenienti dai sensori piezoelettrici disposti sulla superficie del pannello, per predire il livello di energia degli impatti. A tale scopo, le misure di tensione prodotte da tali sensori durante l'impatto, vengono raccolte in immagini bidimensionali. A partire da questi input bidimensionali, la rete CNN restituisce come output la classe di energia di impatto più probabile. Analogamente, le reti adottate in questa tesi utilizzano direttamente i segnali degli spostamenti di ciascun sensore, e non solo i relativi valori massimi (come fatto precedentemente con le

reti ANN); potendo così valutare i segnali al variare del tempo. Per questo motivo, rappresentano un potenziale candidato per migliorare le capacità di predire la forza massima e gli angoli di impatto.

Come per le reti neurali artificiali, le reti CNN possono avere un numero illimitato di combinazioni nella loro struttura. È possibile variare la tipologia e la quantità di layer, oppure includere strati che migliorino le prestazioni della rete, come dropout e batch normalization. La valutazione della struttura adatta delle CNN non è banale, poiché non esistono norme precise, in quanto spesso ci si basa sull'esperienza. Come primo approccio, è stato effettuato un numero elevato di tentativi con diverse strutture presenti in pubblicazioni e nel web, al fine di comprendere i range di errori e la loro capacità di estrarre le caratteristiche del problema in esame. Successivamente, è stata scelta la struttura più performante. Questa struttura è stata poi modificata in base alle conoscenze acquisite, per garantire risultati migliori. Per adattare le reti presenti nelle pubblicazioni al compito di regressione, è stato necessario sostituire gli ultimi tre layer della CNN di classificazione (*Fully Connected Layer*, *Softmax Layer* e *Class Output*) con un *Fully Connected Layer* di dimensione 1 e un *Regression Layer*.

Fra le reti testate preventivamente, una che ha garantito performance migliori, è stata quella presente in [54], questa infatti risulta molto accurata e relativamente veloce nell'apprendimento. La rete è strutturata come in Tabella 6.3. Inoltre è stata valutata anche la rete *Efficient Net B0* [60], che consiste in una rete CNN di grandi dimensioni, generalmente pre addestrata per la classificazione di immagini. Tale rete risulta molto più complessa, in grado di rilevare caratteristiche e dettagli con particolare efficacia. È stata scelta per valutare se effettivamente l'uso di una rete di tale complessità potesse garantire predizioni più accurate.

Layer	Tipo	Parametri
1	Image Input	
2	Convolution	6 Filtri [5,5]
3	ReLu	
4	Batch Normalization	
5	Max Pooling	[2,2], Stride [3,3]
6	Convolution	16 Filtri [5,5]
7	Batch Normalization	
8	ReLu	
9	Max Pooling	[2,2], Stride [2,2]
10	Convolution	120 Filtri [5,5]
11	Batch Normalization	
12	ReLu	
13	Fully Connected	
14	Soft Max	
15	Classification	16

**Tabella 6.3:** Struttura usata in [54].

La struttura della Rete 1 in Tabella 6.4, si basa sulla struttura indicata in Tabella 6.3. Le modifiche effettuate, consistono nella sostituzione degli ultimi 3 layer con quelli adatti alla regressione. Inoltre, è stato sostituito il layer 10 con un filtro più piccolo pari a [1,1], in modo tale da adattare la rete alle dimensioni degli input usati. Sono stati mantenuti i pooling layer di tipo maxpool di dimensione [2,2], in quanto i maxpool risultano più efficienti e con performance migliori [22].

Nel processo di selezione delle funzioni di attivazione, la Tanh e la Sigmoid sono state scartate poiché entrambe soffrono del problema della scomparsa del gradiente, portando in alcuni casi alla lenta convergenza della rete o all'incapacità di addestrarla. Al contrario, la funzione ReLU non presenta tale fenomeno ed ha mostrato buoni risultati in varie fasi preliminari. Tuttavia, può verificarsi che nel processo di addestramento alcuni neuroni non rispondano durante la retropropagazione, producendo un gradiente nullo e rendendo parti della rete inattive, comportando la "morte" di tali neuroni. Tale problema è noto come *dying ReLU* [22], per questo motivo spesso si adottano varianti di ReLU, come la LeakyReLU, che mantiene i vantaggi della funzione ReLU senza incorrere nel problema del *dying ReLU*; grazie a un comportamento non nullo per input inferiori a 0 durante il processo di retropropagazione. Per questa motivazione è stata

adottata la funzione di attivazione LeakyReLU.

Layer	Tipo	Parametri
1	Image Input	-
2	Convolution	6 Filtri [5,5]
3	Batch Normalization	-
4	Leaky ReLu	-
5	Max Pooling	[2,2], Stride [3,3]
6	Convolution	16 Filtri [5,5]
7	Batch Normalization	-
8	Leaky ReLu	-
9	Max Pooling	[2,2], Stride [2,2]
10	Convolution	120 Filtri [1,1]
11	Batch Normalization	-
12	Leaky ReLu	-
13	Fully Connected	1
14	Regression	-

**Tabella 6.4:** Definizione Rete 1 con Array4D.

La presenza di più layer convoluzionali garantisce alla rete di apprendere caratteristiche più complesse. Ogni filtro di tali layer, genera una mappa delle caratteristiche. I primi layer convoluzionali identificano caratteristiche più semplici, come i bordi, e man mano che i layer convoluzionali aumentano più aumenta la capacità di identificare caratteristiche complesse. È stato inoltre adottato il batch normalization layer per aumentare la stabilità e le prestazioni della rete, aiutando ad accelerare l'addestramento. In questo modo la rete diventa meno sensibile ai valori iniziali dei pesi e contribuisce a mitigare problemi come la scomparsa o l'esplosione del gradiente. Infine il layer pienamente connesso (o *fully connected*) è un layer di neuroni corrispondenti a quelli delle reti neurali artificiali. Ha lo scopo di riunire le informazioni estratte dai layer precedenti e genera un risultato scalare, fondamentale al compito di regressione.

Durante il processo di addestramento è evidente l'effetto del *learning rate*, il quale, adeguato per ciascuna simulazione. Learning rate troppo grandi infatti possono portare la loss function a crescere (invece che a decrescere), impedendo alla rete di apprendere correttamente. Al contrario Learning rate troppo piccoli, portano la rete a convergere troppo lentamente [52]. La scelta dell'algoritmo di ottimizzazione, invece non influisce particolarmente sull'accuratezza dei risultati,

bensì sulla velocità dell'addestramento [54]. Per questo motivo è stato usato l'ottimizzatore di *stochastic gradient descent with momentum*, il quale è risultato idoneo al problema analizzato. Come per le reti ANN presentate precedentemente l'ottimizzatore ha la funzione di far variare i parametri (i pesi e i bias) della rete minimizzando il più possibile la *loss function*. La *loss function* e il parametro per valutare le performance della rete sono basati sulla radice quadratica dell'errore quadratico medio, o RMSE (*Root Mean Squared Error*).

È stata introdotta la Rete 2 per la ricostruzione dell'angolo  $\phi$  negli impatti sul piano. La struttura di tale rete, indicata in Tabella 6.5, è una variante della Rete 1. È stata sviluppata per migliorare le previsioni degli angoli  $\phi$ . A tal fine, sono stati adottati più filtri di convoluzione e pooling, e sono state modificate le dimensioni dei filtri in modo che questi agiscano su una colonna alla volta degli input, ossia nella direzione temporale dei segnali di ciascun singolo sensore; senza effettuare operazioni convoluzionali che coinvolgessero i canali di più sensori. Con questa rete sono stati analizzati due casi per la predizione dell'angolo  $\phi$  nel piano: nel primo caso sono stati utilizzati i segnali relativi a 24 sensori, mentre nel secondo caso sono stati usati tutti e 40 i sensori. Nella configurazione a 24 sensori, l'RMSE è risultato maggiore dell'1% e il tempo di addestramento è stato il 57% più lungo rispetto a quello ottenuto con la Rete 1. Usando la configurazione a 40 sensori, la Rete 2, sebbene richieda il 50% di tempo in più durante il processo di *training*, presenta un RMSE di  $13.8^\circ$  rispetto ai  $14.7^\circ$  trovati per la prima rete. Anche l'errore medio migliora, passando da  $-2^\circ$  a  $-1^\circ$ . In questo modo la Rete 2, con i segnali di 40 sensori, garantisce un miglioramento delle prestazioni nella stima dell'angolo di impatto  $\phi$ . Per cui, la scelta di reti con strutture più complesse, può portare a predizioni più accurate in presenza di input contenenti più informazioni. Tuttavia, con input più semplici (ad esempio che adottano meno sensori), le reti complesse non garantiscono lo stesso vantaggio. È inoltre da considerare che l'incremento della complessità della struttura di rete comporta un aumento del tempo di calcolo.

Layer	Tipo	Parametri
1	Image Input	-
2	Convolution	6 Filtri [5,1]
3	Batch Normalization	-
4	Leaky ReLu	-
5	Max Pooling	[2,1], Stride [3,3]
6	Convolution	16 Filtri [5,1]
7	Batch Normalization	-
8	Leaky ReLu	-
9	Max Pooling	[2,1], Stride [2,2]
10	Convolution	120 Filtri [5,1]
11	Batch Normalization	-
12	Leaky ReLu	-
13	Max Pooling	[2,1], Stride [2,2]
14	Convolution	120 Filtri [5,1]
15	Batch Normalization	-
16	Leaky ReLu	-
17	Dropout Layer	-
18	Fully Connected	1
19	Regression	-

**Tabella 6.5:** Definizione Rete 2 con Array4D.

### 6.3.1 Scelta degli Input e dei Target

Si possono usare reti CNN per predire una moltitudine di informazioni relative a un determinato impatto, come l'energia, la posizione [22], l'area di delaminazione [27], la forza di impatto e molte altre. A tale scopo, è necessario scegliere adeguatamente i dati da inserire come input, ad esempio selezionandone la disposizione, il formato e l'eventuale applicazione di una normalizzazione.

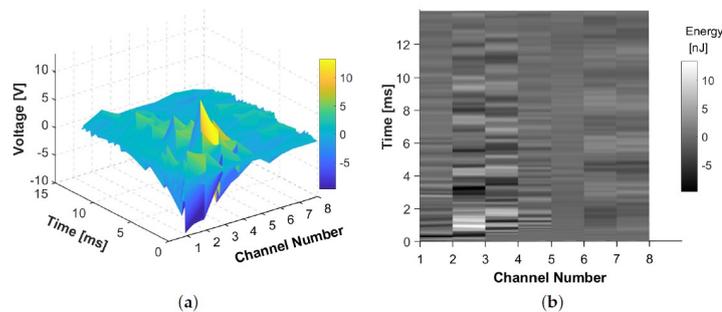
Le CNN in Matlab acquisiscono gli input in formato tabulato, o attraverso immagini "jpg" o "png", o formati numerici come gli Array4D. La scelta del formato e la struttura dei dati in input alle reti risulta importante ai fini di avere predizioni accurate. In letteratura si evidenzia che la scelta della struttura dei dati in input non è univoca; infatti, nelle varie pubblicazioni si seguono percorsi diversi. Non esistendo delle linee guida, le scelte vengono motivate dalla natura fisica del

Hyperparameter	Increases capacity when...	Reason	Caveats
Number of hidden units	increased	Increasing the number of hidden units increases the representational capacity of the model.	Increasing the number of hidden units increases both the time and memory cost of essentially every operation on the model.
Learning rate	tuned optimally	An improper learning rate, whether too high or too low, results in a model with low effective capacity due to optimization failure.	
Convolution kernel width	increased	Increasing the kernel width increases the number of parameters in the model.	A wider kernel results in a narrower output dimension, reducing model capacity unless you use implicit zero padding to reduce this effect. Wider kernels require more memory for parameter storage and increase runtime, but a narrower output reduces memory cost.
Implicit zero padding	increased	Adding implicit zeros before convolution keeps the representation size large.	Increases time and memory cost of most operations.
Weight decay coefficient	decreased	Decreasing the weight decay coefficient frees the model parameters to become larger.	
Dropout rate	decreased	Dropping units less often gives the units more opportunities to "conspire" with each other to fit the training set.	

Table 11.1: The effect of various hyperparameters on model capacity.

**Figura 6.4:** Consigli sulla scelta di iperparametri [52]

problema o seguendo altre valutazioni di tipo logico. Data anche l'assenza di ricerche che proponessero metodologie efficaci per predire le caratteristiche di urti inclinati, l'approccio si è concentrato nell'usare tecniche note per gli impatti perpendicolari. Una scelta comune alle ricerche che fanno uso di CNN per la caratterizzazione di tali impatti [22], [27], [37] e [38], è di usare immagini o tabelle generate per ciascun evento di impatto, contenenti i dati estrapolati dai sensori. I segnali dei sensori vengono disposti in colonne, in modo tale che ogni colonna rappresenti l'ampiezza del segnale misurato da ciascun sensore nel tempo, come rappresentato nella Figura 6.5.

**Figura 6.5:** Esempio di (a) mappa superficiale della tensione registrata dai sensori PZT e (b) vista 2D in scala di grigi. [22]

Nella tesi di laurea di [27], viene analizzata la possibilità di inserire distinta-

mente le misure dei sensori lungo i tre assi x, y, z, ottenendo degli input triassiali. Questo avviene inserendo in colonne, le misure rilevate per ogni asse dei sensori durante l'impatto. L'ampiezza di tali segnali vengono tradotti in scala di grigi, ottenendo delle immagini bianco e nero. Tuttavia, è stato evidenziato che per impatti perpendicolari non c'è particolare rilevanza tra input triassiale o monoassiale nell'addestramento delle CNN. È logico pensare, però, che in impatti inclinati, input triassiali potrebbero fornire informazioni utili per identificarne le caratteristiche.

Sono state sviluppate due metodologie per inserire i dati nelle CNN. La prima prevede l'addestramento della rete utilizzando immagini organizzate in cartelle di Train, Validation e Test, richiamate tramite un *imagedatastore* definito in Matlab. Ogni immagine, identifica una simulazione di un impatto, per cui sono presenti 200 immagini per gli urti centrali e 1600 immagini per gli urti nel piano. Ciascuna immagine è associata ai relativi valori di target mediante una struttura a celle (*Cell Array*). Nella prima colonna delle celle, ad esempio per la variabile Train, è stato inserito l'indirizzo di ciascuna immagine presente nell'*imagedatastore*; mentre nella seconda colonna è presente il relativo valore target. I target inseriti sono quelli relativi al problema da risolvere: i valori di forza massima per la determinazione della forza di impatto massima, gli angoli  $\phi$  per l'identificazione dell'angolo, e infine gli angoli  $\theta$ . In modo analogo la stessa operazione è stata effettuata per i dati di Validation e Test.

```
1 net = trainNetwork(TRAIN, layers, options)
```

**Listing 6.1:** Definizione rete con imagedatastore.

Il secondo metodo, consiste nell'uso degli *Array4D*. Invece di creare direttamente le immagini contenenti le informazioni dei sensori, si creano dei tabulati che mantengono una struttura analoga. Gli *Array4D* sono dei tensori del quarto ordine, definiti analogamente ad una immagine ma con precisione di tipo *double*. Gli *Array4D* vengono identificati da 4 indici. Nelle prime 2 posizioni si identificano le coordinate del pixel, nella terza identifica il canale (o colore) e nel quarto si identifica il numero di immagine (ossia la simulazione o l'impatto effettuato). I canali adottati per le immagini sono 3: i colori "RGB", rispettivamente rosso (R), verde (G) e blu (B).

$$TRAIN4D = (m, n, c, s) \quad (6.3.1)$$

Ad esempio il canale blu (canale 3) di una immagine  $m \times n$ , della 11<sup>a</sup> simula-

zione sarà salvato nella posizione  $Array4D(:, :, 3, 11)$ . Dove le prime 2 posizioni indicano rispettivamente le posizione di ciascun pixel. Questo metodo presenta importanti vantaggi, in quanto una volta tradotti i dati ottenuti dalle simulazioni in  $Array4D$ , risulta più veloce modificare tali informazioni: alterando ad esempio le dimensioni degli input da adottare; risulta più semplice applicare normalizzazioni, o altre trasformazioni nei dati; risulta più veloce scegliere i target desiderati; e si può variare facilmente le dimensione dei set di *Train*, *Validation* e *Test*. Nel caso degli  $Array4D$ , i target non vengono più inseriti come etichette, come nel caso dell'*imagedatastore*, ma bensì come vettore colonna direttamente nella definizione della rete.

```
1 net = trainNetwork(TRAIN4D, TargetTrain, layers, options)
```

**Listing 6.2:** Definizione rete con  $Array4D$ .

L'utilizzo dei due metodi non ha evidenziato differenze in termini di risultati, e per questo motivo è stato adottato il secondo. Nello specifico gli  $Array4D$  sono risultati più adattabili alla normalizzazione dei dati. Applicare la normalizzazione alle immagini, risulta macchinoso e dispendioso in termini di tempo e costi computazionali; decretando un indubbio vantaggio nell'uso degli  $Array4D$ .

I dati estratti dalle simulazioni in Abaqus, comprendono i segnali dei sensori dall'istante temporale in cui inizia la simulazione, per cui considerando anche il momento antecedente all'impatto. Tuttavia, dal punto di vista pratico e sperimentale, è necessario adottare un metodo univoco per identificare l'inizio dell'impatto. Per questo motivo è stata adottata una soglia, che scarta gli istanti temporali precedenti alla prima misurazione. Gli istanti temporali, sono associati alla frequenza di campionamento, e nel caso degli spostamenti si usano 500 incrementi temporali che valgono ciascuno  $5 \cdot 10^{-6} s$ .

Le CNN apprendono meglio se i dati inseriti, variano all'interno di un range fra 0 e 1, o fra -1 e 1 se i dati presentano una qualche forma di simmetria. Per cui risulta una utile normalizzare i dati in input.

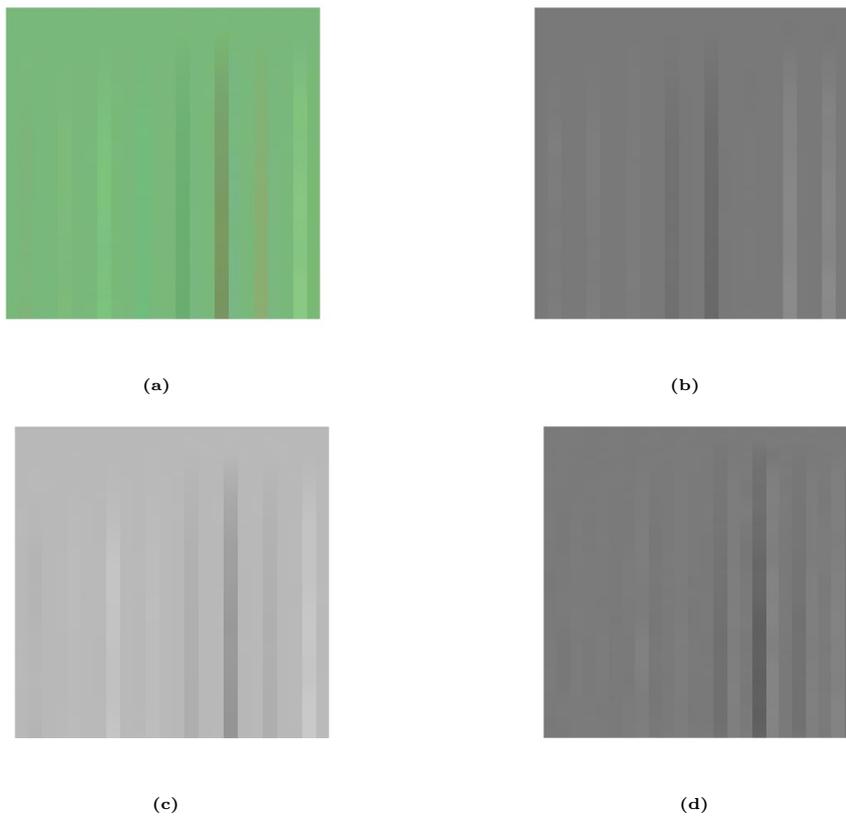
Normalizzazione fra 0 e 1:

$$Normalizzazione = \frac{X - min}{max - min} \quad (6.3.2)$$

Normalizzazione fra -1 e 1:

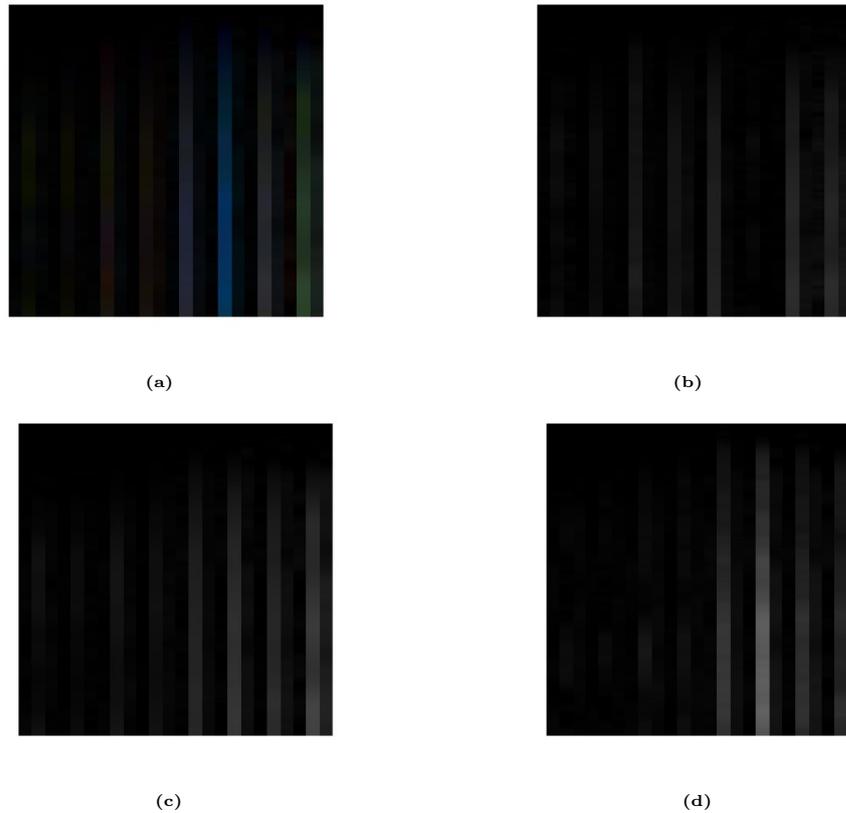
$$Normalizzazione = 2 \cdot \frac{X - min}{max - min} - 1 \quad (6.3.3)$$

Dove  $X$  è il segnale da normalizzare,  $max$  e  $min$  invece rappresentano i relativi valori massimi e minimi assunti da  $X$ . In questo caso gli elementi costituenti la matrice di input sono normalizzati in un range che varia tra fra 0 e 1 (Eq. 6.3.2).



**Figura 6.6:** Esempio di normalizzazione con 24 sensori di spostamento sul range di valori assunti fra minimo e massimo di tutti i sensori. a) Sono presenti i canali XYZ in una immagine RGB, b) è presente solo il canale X in una immagine in scala di grigi, c) è presente il canale Y in una immagine in scala di grigi, d) è presente solo il canale Z in una immagine in scala di grigi.

Applicando l'Equazione 6.3.2, inserendo i valori massimi e minimi misurati per tutti i sensori di tutte le simulazioni, si ottengono delle immagini pari a quelle illustrate in Figura 6.6.



**Figura 6.7:** Esempio di normalizzazione con 24 sensori di spostamento. a) Sono presenti i canali XYZ in una immagine RGB, b) è presente solo il canale X in una immagine in scala di grigi, c) è presente il canale Y in una immagine in scala di grigi, d) è presente solo il canale Z in una immagine in scala di grigi.

Queste rappresentano un primo tentativo di normalizzazione, che però presentava alcune criticità. Risulta infatti frequente che alcuni sensori siano più sensibili agli spostamenti rispetto ad altri. La ragione di questo fenomeno, è associata alla struttura del pannello considerato. Gli irrigidimenti, riducono gli spostamenti localmente, riducendo di conseguenza i range dei sensori nei loro pressi. Tale problema è stato ovviato effettuando una nuova normalizzazione, non più per tutti i sensori, ma per ciascun singolo sensore. In modo tale che i segnali dei sensori vengano normalizzati, sugli effettivi range misurati da ciascun sensore. Quest'ultima normalizzazione viene applicata al valore assoluto dei segnali dei sensori, in modo tale da rendere nulli i risultati dei sensori poco perturbati o non perturbati, e di conseguenza ridurre la loro influenza durante il processo di addestramento delle reti.

Ricapitolando, il nuovo set di immagini o più precisamente  $Array_4D$  normalizzato, viene ottenuto seguendo i seguenti passaggi:

1. Viene preso il valore assoluto delle misure dei sensori, in modo da avere solo

valori positivi nelle matrici.

2. Nelle matrici ottenute precedentemente, viene trovato l'insieme di valori massimi per ciascun sensore e per ogni direzione misurata, per tutte le simulazioni effettuate.
  
3. Viene normalizzato ciascun segnale, attraverso l'Equazione 6.3.4, dividendo la colonna associata a tale misurazione per il valore massimo trovato precedentemente. Ciò agisce come una "calibrazione" dei sensori, e viene effettuata non solo per ciascun sensore, ma anche per ciascun suo asse di misura.

$$\text{Normalizzazione} = \frac{|X|}{\max} \quad (6.3.4)$$

Anche per le reti CNN risulta importante valutare le configurazioni dei sensori adottate. Sono state prese in considerazione le configurazioni illustrate in Figura 5.10, analizzandone le performance legate alla stima del picco della forza di impatto. A tale scopo sono state usate 1600 simulazioni di impatti nel piano, variando il numero di sensori e le loro disposizioni; ottenendo i risultati riportati in Tabella 6.7. A tale scopo è stata adottata la Rete 3, indicata in Tabella 6.6, è una versione modificata della Rete 1 (Tab. 6.4). Tale rete CNN è stata adottata poiché la Rete 1 non risultava adeguata alle nuove dimensioni delle immagini in input. Riducendo il numero di sensori adottati, si riduce anche il numero di colonne delle immagini in input, rendendo la Rete 1 non più adeguata a tali dimensioni. Le modifiche apportate nella Rete 3 riguardano quindi le dimensioni dei filtri, in modo da ridurre il numero di colonne che ciascun filtro prende in considerazione. I layer convoluzionali passano da dimensione [5 5] a [5 1], mentre quelli di maxpool passano da [2 2] a [2 1].

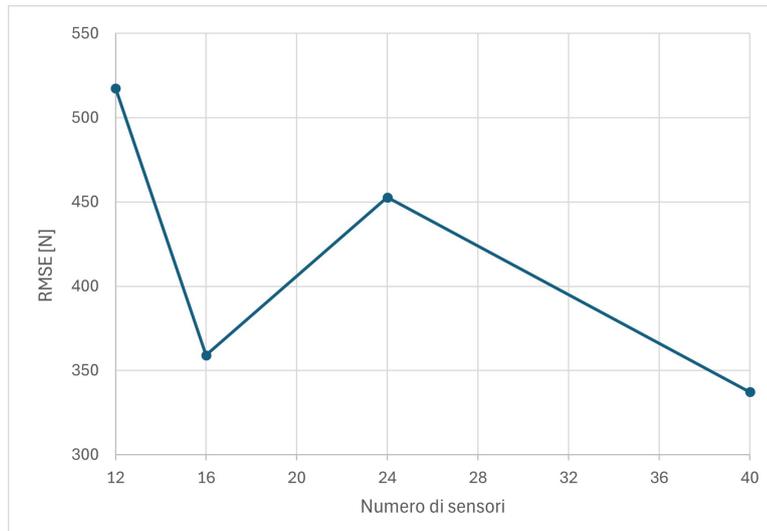
Layer	Tipo	Parametri
1	Image Input	-
2	Convolution	6 Filtri [5,1]
3	Batch Normalization	-
4	Leaky ReLu	-
5	Max Pooling	[2,1], Stride [3,3]
6	Convolution	16 Filtri [5,1]
7	Batch Normalization	-
8	Leaky ReLu	-
9	Max Pooling	[2,1], Stride [2,2]
10	Convolution	120 Filtri [1,1]
11	Batch Normalization	-
12	Leaky ReLu	-
13	Fully Connected	1
14	Regression	-

**Tabella 6.6:** Definizione Rete 3 con Array4D.

Dai risultati ottenuti per le varie configurazioni di sensori, si osserva che la configurazione a 12 sensori presenta i risultati peggiori, con deviazione standard degli errori relativi e RMSE più elevati. Incrementando il numero di sensori i risultati migliorano garantendo il minore RMSE, pari a  $337.3N$  per la configurazione che comprende 40 sensori. Ciò suggerisce che incrementando il numero di sensori si garantiscano risultati migliori. Tuttavia è da notare che ciò non è sempre vero, in quanto la configurazione a 16 sensori, ha una RMSE di  $359.1N$ , nettamente inferiore a quella ottenuta per 24 sensori. È da tenere conto che, almeno in parte, questi risultati possono essere attribuiti alla natura stocastica dei parametri iniziali della rete.

Sensori	RMSE [N]	Err. medio [N]	Err. medio %	DevSt
12	517.3	181.9	4.9	0.34
16	359.1	-25.8	-10.0	0.29
24	452.7	78.4	-0.4	0.33
40	337.3	-37.0	-8.8	0.28

**Tabella 6.7:** Miglioramento delle prestazioni delle CNN al variare di sensori inseriti. Dati in input spostamenti normalizzati fra 0 e 1 per ciascun sensore, per la stima della forza di impatto con la rete Rete 6.6, per gli impatti nel piano.

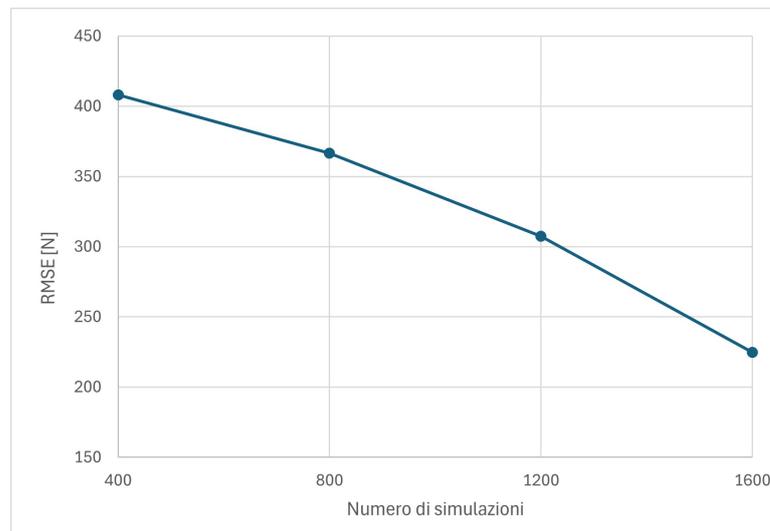


**Figura 6.8:** Andamento delle RMSE delle CNN al variare del numero di sensori.

Poiché eseguire numerose simulazioni per addestrare le reti è molto oneroso dal punto di vista computazionale, è importante esaminare le prestazioni delle reti al variare del numero di simulazioni. Questo permette di quantificare il numero di simulazioni effettivamente necessarie affinché le reti possano predire accuratamente il picco della forza di impatto. A tale scopo è stata adottata la Rete 1 (Tab. 6.4) con 40 sensori. Dai risultati in Tabella 6.8 si evidenzia che all'aumentare del numero di simulazioni adottate l'RMSE diminuisce, per cui le prestazioni aumentano. Tuttavia è interessante notare che a fra 800 e 1200 simulazioni si evidenzia un minore effetto sulla deviazione standard degli errori relativi, mentre 1600 ha garantito risultati nettamente migliori. La Figura 6.9, suggerisce inoltre che incrementando ulteriormente il numero di simulazioni l'RMSE possa ridursi ancora.

N sim	RMSE [N]	Err. medio [N]	Err. medio %	DevSt
400	408.0	31.8	-4.1	0.29
800	366.7	21.3	-2.7	0.23
1200	307.3	28.1	-3.6	0.22
1600	224.7	3.4	0.02	0.17

**Tabella 6.8:** Andamento delle prestazioni delle CNN al variare del numero di simulazioni considerate. Dati in input spostamenti normalizzati fra 0 e 1 per ciascun sensore, per la stima della forza di impatto con la Rete 1 (Tab. 6.4), per gli impatti nel piano.



**Figura 6.9:** Andamento delle RMSE delle CNN al variare del numero di simulazioni considerate.



# Capitolo 7

## Risultati

### 7.1 Risultati per impatti in posizione centrali

Prima di procedere agli impatti su tutto il piano è stata valutata l'efficacia delle reti nel predire il picco di forza per impatti in posizione centrale. Lo scopo è di valutare le capacità delle reti con modelli a complessità crescente. In tal modo è stato anche possibile verificare il corretto funzionamento degli script ed evidenziare eventuali prime difficoltà. Il processo di addestramento prevede l'uso di 200 simulazioni, con una divisione dei dati in tre set, *train*, *validation* e *test*. I primi due, rispettivamente di 145 e 25 simulazioni, sono usati durante il processo di training, mentre il set di *test*, di 30 simulazioni, viene adoperato per valutare le *performance* reali delle reti.

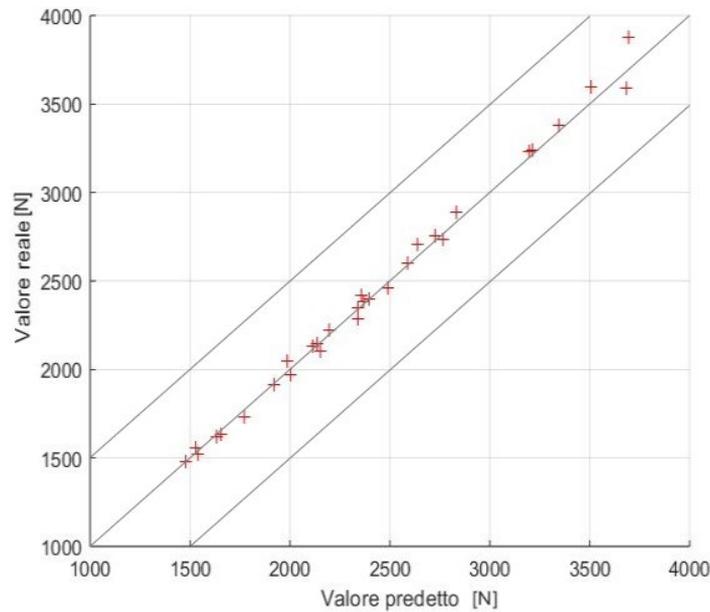
In input alle ANN è stata utilizzata la matrice contenente gli spostamenti massimi misurati da ciascun sensore e il tempo di arrivo del segnale.

Le CNN invece, presentano in input le informazioni in forma di *4DARRAY* con 40 sensori normalizzati al valore massimo.

#### 7.1.1 Predizione della forza di impatto massima

Sia le reti neurali artificiali (ANN) che quelle convoluzionali (CNN) hanno dimostrato un'ottima capacità di predizione del picco della forza di impatto.

Nel caso delle ANN, il processo di ottimizzazione del numero dei layer ha portato a una struttura piuttosto semplice, composta da tre *hidden layer* con rispettivamente 4, 5 e 3 neuroni. Questo processo di ottimizzazione consiste nel variare il numero di neuroni all'interno di un intervallo e nel valutare la deviazione standard degli errori commessi sul set di *test*, scartando le configurazioni che



**Figura 7.1:** Grafico in cui si confrontano i valori di forza predetti con quelli reali nel set di test, con la rete 4-5-3. La linea diagonale centrale rappresenta i risultati ideali, mentre le altre 2, identificano un range di errore di  $\pm 500N$ .

presentavano errori medi e massimi eccessivi. La rete ottimale presenta un RMSE di  $53.4N$ , un errore percentuale medio dell'1.5% e un errore massimo del 4.7%. Questa rete ha dimostrato un'ottima precisione, come si può osservare in Figura 7.1, con una deviazione standard degli errori relativi pari a 0.02.

Risultati analoghi si ottengono anche con le reti neurali convoluzionali (CNN). La distribuzione degli errori risulta ben centrata, con un errore medio pari allo 0.9%. Sebbene l'RMSE, pari a  $68.9N$ , sia leggermente superiore a quello ottenuto con le ANN, la deviazione standard degli errori relativi rimane invariata, pari a 0.02. Le due reti considerate sono perfettamente paragonabili e presentano entrambe caratteristiche molto promettenti.

Rete	RMSE [N]	Err. medio %	DevSt
ANN 4-5-3	53.4	4.7	0.02
CNN Rete 1	68.9	0.9	0.02

**Tabella 7.1:** Prestazioni delle reti adottate per la determinazione dei picchi di forza degli impatti centrali. La rete ANN presenta la configurazione 4-5-3 e la CNN adottata presenta la struttura della Rete 1 (Tab. 6.4).

### 7.1.2 Predizione dell'angolo $\phi$

Per l'angolo di impatto rispetto al piano,  $\phi$ , emergono le prime difficoltà nella sua caratterizzazione.

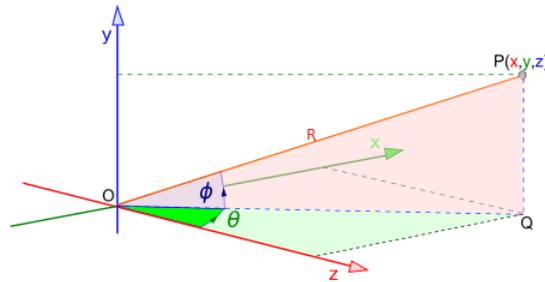


Figura 7.2: Angoli usati.

La rete neurale artificiale ottimizzata presenta una configurazione con tre *hidden layer* di 5, 10 e 15 neuroni rispettivamente. Questa rete ha mostrato una minore accuratezza nella predizione degli angoli. L'RMSE è infatti di  $10.7^\circ$ , con un errore massimo in valore assoluto di  $16.8^\circ$  e una media di  $-5^\circ$ , indicando una leggera sottostima degli angoli.

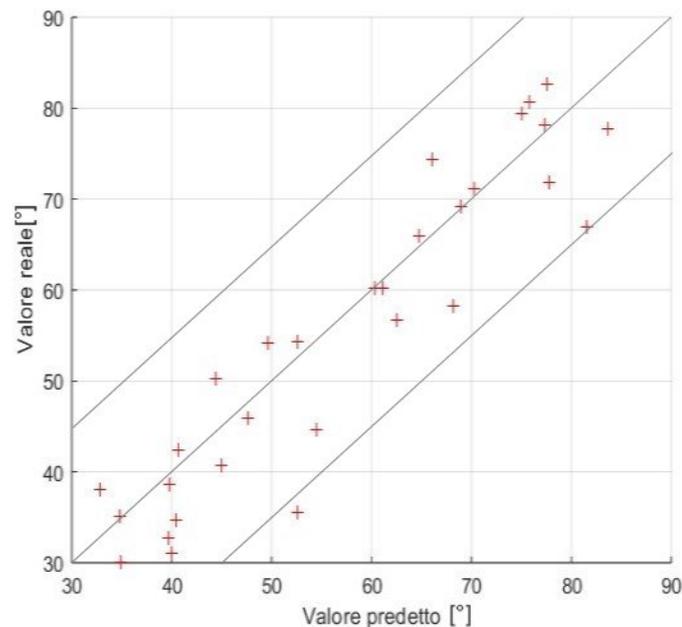
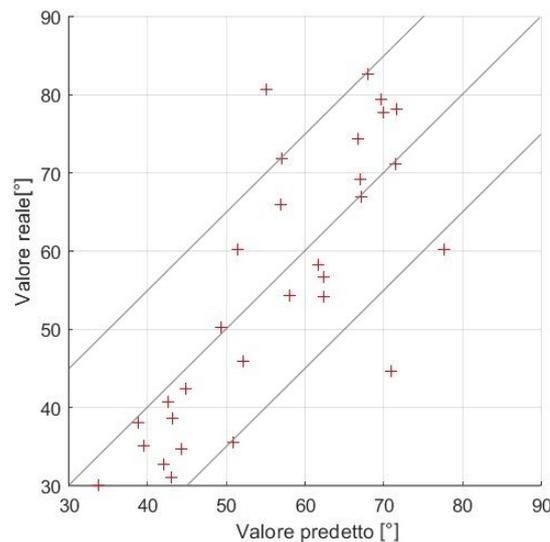


Figura 7.3: Grafico in cui si confrontano i valori di  $\phi$  predetti con quelli reali nel set di test, con la rete 5-16-5. La linea diagonale centrale rappresenta i risultati ideali, mentre le altre 2, identificano un range di errore di  $\pm 15^\circ$ .

La CNN applicata all'angolo  $\phi$  presenta la struttura della Rete 2 (Tab. 6.5). Questa struttura ha garantito risultati poco più incerti rispetto al caso precedente. Nonostante l'RMSE e media siano paragonabili a quelli ottenuti per le reti ANN, pari rispettivamente a  $10.5^\circ$  per l'RMSE e  $-2.1^\circ$  per la media; si possono osservare in Figura 7.4 alcune predizioni che si discostano significativamente dai valori reali, con un errore massimo che raggiunge i  $25.1^\circ$ .

In questo caso, le reti hanno mostrato una maggiore difficoltà nel predire i valori corretti rispetto alle predizioni di forza massima. Sebbene l'RMSE sia paragonabile, le reti neurali artificiali hanno garantito una distribuzione migliore (Fig. 7.3) rispetto a quella ottenuta con la rete CNN (Fig. 7.4).



**Figura 7.4:** Distribuzione dei valori predetti con la rete CNN per  $\phi$ . La linea diagonale centrale rappresenta i risultati ideali, mentre le altre 2, identificano un range di errore di  $\pm 15^\circ$ .

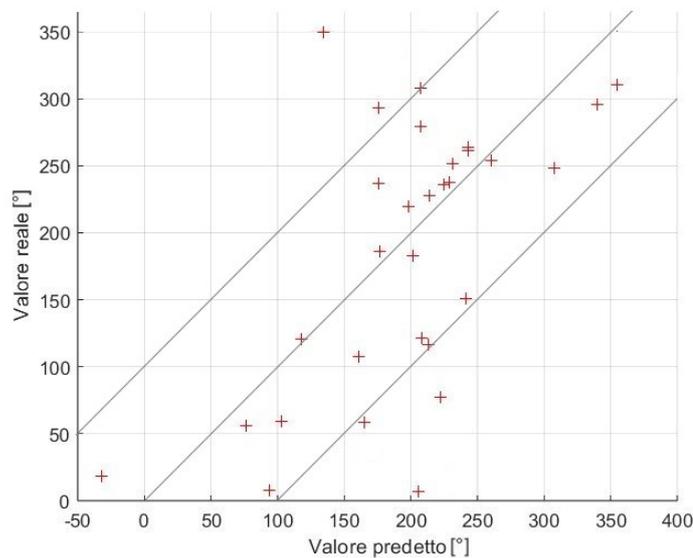
Rete	RMSE [°]	Err. medio [°]
ANN 5-16-5	10.7	-5
CNN Rete 2	10.5	-2.1

**Tabella 7.2:** Prestazioni delle reti adottate per la determinazione dell'angolo  $\phi$  degli impatti centrali. La rete ANN presenta la configurazione 5-16-5, mentre la CNN adottata presenta la struttura della Rete 2 (Tab. 6.5).

### 7.1.3 Predizione dell'angolo $\theta$

Le reti adottate per predire  $\theta$  hanno dimostrato diverse criticità fin dalla scelta dei target. La difficoltà iniziale era legata alla necessità di individuare una metodologia per inserire i valori di  $\theta$  tenendo conto della periodicità di tale angolo.

Infatti, nelle predizioni degli angoli vicini a  $0^\circ$  e  $360^\circ$ , la rete avrebbe avuto difficoltà durante l'addestramento per garantire il corretto errore. Matlab, infatti, non tiene conto dell'aspetto periodico degli angoli. Per questo motivo è stato valutato preliminarmente il comportamento sia inserendo direttamente  $\theta$  in gradi, sia il  $\cos(\theta)$ , in modo che la stima dell'errore fosse coerente con la periodicità. Utilizzando la funzione coseno, essendo periodica ogni  $180^\circ$  e non ogni  $360^\circ$ , si sarebbe persa la capacità di predire correttamente metà delle soluzioni. Tuttavia, questo approccio non è risultato significativo. Sorprendentemente, si sono ottenute predizioni migliori usando direttamente  $\theta$ .

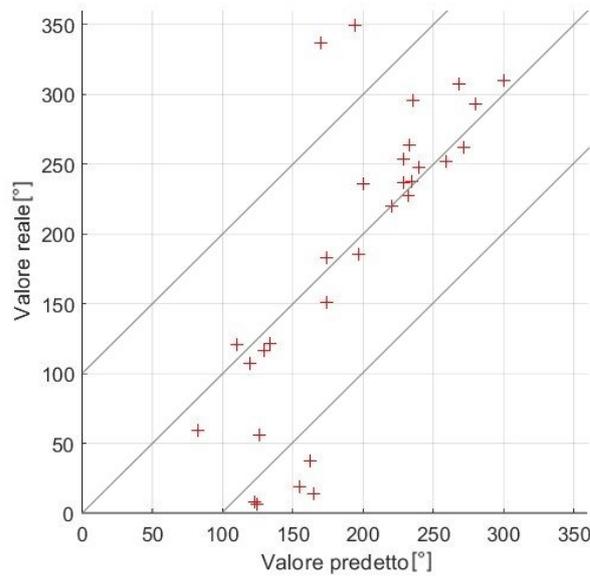


**Figura 7.5:** Distribuzione dei valori predetti con la rete ANN per  $\theta$  10-13-12. La linea diagonale centrale rappresenta i risultati ideali, mentre le altre 2, identificano un range di errore di  $\pm 100^\circ$ .

Le reti neurali artificiali hanno dato un RMSE di  $61.8^\circ$ , nonostante la rete sia stata ottimizzata minimizzandolo nella configurazione di neuroni 10-13-12 per i tre *hidden layer*. L'uso di reti con più *hidden layer* non ha restituito risultati più accurati. Confrontando i valori predetti con quelli reali, la Figura 7.5 dimostra una discreta predizione per i range degli angoli compresi tra  $0^\circ$  e  $150^\circ$ , e tra  $250^\circ$  e  $360^\circ$ . Tuttavia, nel range tra  $150^\circ$  e  $250^\circ$  le reti non risultano efficaci.

Anche l'uso delle CNN ha garantito risultati deboli, ma, osservando la Figura 7.6, si nota una migliore capacità di generalizzazione rispetto alle reti neurali artificiali. I valori predetti risultano più compatti, ad eccezione di 6 casi che si discostano significativamente dai valori reali. L'errore medio è di  $-8.5^\circ$ , evidenziando una leggera sottostima dei valori predetti; mentre l'RMSE è di  $71^\circ$ , ri-

sultando di poco maggiore rispetto a quello ottenuto con le ANN, ma comunque paragonabile.



**Figura 7.6:** Grafico in cui si confrontano i valori dell'angolo  $\theta$  predetti con quelli reali nel set di test con la rete CNN. La linea diagonale centrale rappresenta i risultati ideali, mentre le altre 2, identificano un range di errore di  $\pm 100^\circ$ .

Rete	RMSE [°]	Err. medio [°]
ANN 10-13-12	61.8	14.0
CNN Rete 2	71	-8.5

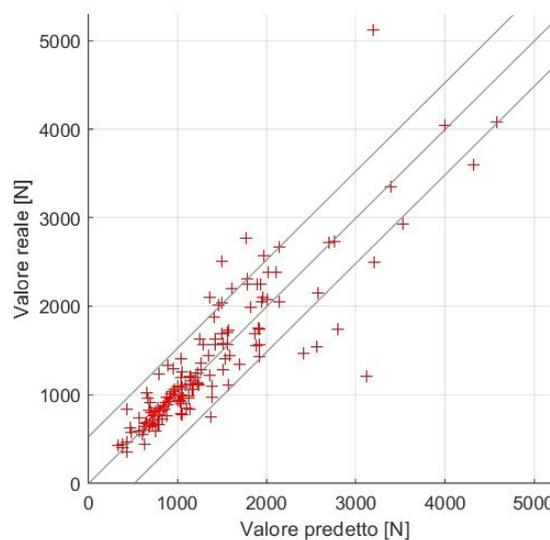
**Tabella 7.3:** Prestazioni delle reti adottate per la determinazione dell'angolo  $\theta$  degli impatti centrali. La rete ANN presenta la configurazione 10-13-12, mentre la CNN adottata presenta la struttura della Rete 2 (Tab. 6.5).

## 7.2 Risultati per impatti sul piano

Dati i risultati promettenti delle reti neurali artificiali e convoluzionali per gli impatti centrali, sono stati applicati in modo analogo agli impatti sull'intero piano. Il processo di addestramento prevede l'uso di 1600 simulazioni, con una divisione dei dati in tre set, *train*, *validation* e *test*. I primi due, rispettivamente da 1300 e 150 simulazioni, vengono usati durante il processo di training; mentre il set di *test*, di 150 simulazioni, viene adottato per valutare le *performance* e osservare i risultati. Per le reti ANN è stata utilizzata la matrice contenente gli spostamenti massimi e i tempi. Le CNN adottano invece i dati in forma di *Array4D* con 40 sensori normalizzati al valore massimo di ciascun asse e per ogni sensore.

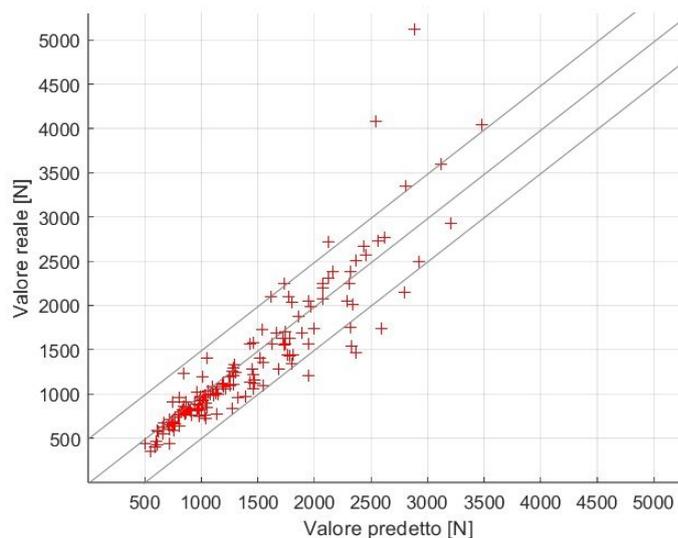
### 7.2.1 Predizione della forza di impatto

Per la predizione del picco della forza di impatto è stata usata la matrice che conteneva gli spostamenti massimi e tempi d'arrivo dei segnali di 40 sensori. La rete neurale artificiale, infatti è stata ottimizzata per queste caratteristiche, ottenendo tre *hidden layer* con rispettivamente 30, 10 e 10 neuroni. I risultati di tale rete presentano una equa distribuzione dei valori predetti, infatti, nel set di test, risulta un errore medio percentuale di 1.6%.



**Figura 7.7:** Grafico in cui si confrontano i valori di forza predetti con quelli reali nel set di test, con la rete 30-10-10. La linea diagonale centrale rappresenta i risultati ideali, mentre le altre 2, identificano un range di errore di  $\pm 500N$ .

L'errore massimo percentuale è di 159.3%, tuttavia sono solo 13 su 150 i valori predetti che superano l'errore del 30%. La deviazione standard degli errori relativi è di 0.21, con un RMSE 379.8N in un range di forze comprese tra 500N e 5000N. La determinazione del picco di forza di impatto risulta quindi predetta coerentemente allo scopo del problema analizzato. È stata verificata l'efficacia della tecnica dell'*ensemble* per migliorare le capacità predittive delle reti neurali artificiali. L'*ensemble* consiste nell'addestramento di più reti, per poi mediane i risultati. Sono state adottate a tale scopo 12 reti con la stessa configurazione di layer. Garantendo una netta riduzione dell'errore massimo percentuale dal 159.3% al 64.8% e un RMSE di 340N. Questo tipo di reti, ha portato però l'errore percentuale medio a  $-10\%$ , sottostimando in media le predizioni.



**Figura 7.8:** Grafico in cui si confrontano i valori di forza predetti con quelli reali nel set di test, con la rete 30-10-10 di tipo ensemble. La linea diagonale centrale rappresenta i risultati ideali, mentre le altre 2, identificano un range di errore di  $\pm 500N$ .

Di seguito vengono riportati i risultati di alcune prove preliminari presentati nel Capitolo 6. Tali reti mantengono la struttura 30-10-10, sono state valutate le performance al variare del numero di sensori adottati e della matrice di input adottata,  $A$  (Eq. 6.2.1) o  $t|A$  (Eq. 6.2.2).

Le reti che facevano uso dei soli spostamenti massimi (Eq. 6.2.1), sono indicate in Tabella 7.4). Tali reti caratterizzano molto bene la forza di impatto anche con un numero ridotto di sensori, pari a 16 o 24. Evidenziando in questo caso, che non per tutti i problemi l'inserimento di più informazioni garantisce migliori risultati. Infatti, una rete con solo il segnale di spostamento massimo di

Sensori	RMSE [N]	Err. medio [N]	Err. medio %	DevSt
12	505.5	10.9	-7.0	0.31
16	337.1	-26.6	-4.8	0.22
24	274.4	-1.2	-1.3	0.15
40	766.8	-17.8	-30.5	0.72

**Tabella 7.4:** Miglioramento delle prestazioni delle ANN al variare di sensori inseriti. Dati in input spostamenti massimi per la stima della forza di impatto con la rete 30-10-10, per gli impatti nel piano.

24 sensori, ha garantito un RMSE del 19.3% inferiore a quello ottenuto con 40 sensori e le informazioni di tempo e spostamento.

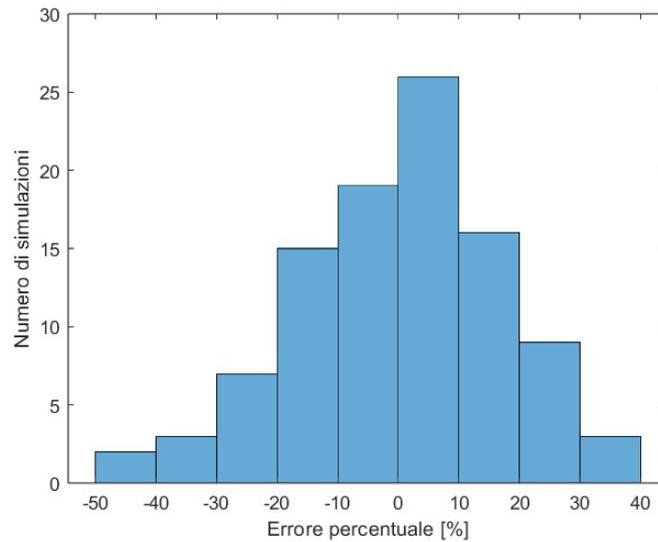
In Tabella 7.5, sono presenti le medesime reti, ma valutando l'uso della matrice contenente sia le informazioni del tempo che lo spostamento massimo (Eq. 6.2.2).

Sensori	RMSE [N]	Err. medio [N]	Err. medio %	DevSt
12	622.8	92.6	-1.6	0.42
16	609.3	-16.5	-13.0	0.49
24	762.8	43.5	-20.0	0.64
40	379.8	9.8	-1.6	0.21

**Tabella 7.5:** Miglioramento delle prestazioni delle ANN al variare di sensori inseriti. Dati in input spostamenti massimi e tempi per la stima della forza di impatto con la rete 30-10-10, per gli impatti nel piano.

In questo caso, l'inserimento di più informazioni, come i tempi di arrivo dei segnali ai sensori, ha generalmente portato a risultati peggiori rispetto all'utilizzo dei soli spostamenti. Tuttavia, è interessante notare che le predizioni migliorano sostanzialmente con l'aumentare del numero dei sensori. Infatti, confrontando i risultati ottenuti con 24 sensori con quelli ottenuti con 40 sensori, si osserva una riduzione del RMSE del 50.1%.

Le reti convoluzionali hanno dimostrato di avere ottime performance, come evidenziato dai risultati di tre reti valutate. Tutte e tre le reti presentano un errore percentuale particolarmente basso, inferiore all'uno per cento. La migliore tra queste è la Rete 1 (Tab. 6.4), caratterizzata da una distribuzione degli errori percentuali ben centrata e priva di errori massimi particolarmente elevati, come illustrato nella Figura 7.9. Il suo RMSE è pari a  $223.7N$ , con una deviazione standard notevolmente bassa di 0.17. Anche la Rete 3 (Tab. 6.6) ha mostrato buone performance, seppur leggermente inferiori. In particolare, l'RMSE risulta essere di  $337.3N$ , con una deviazione standard degli errori relativi di 0.28. Infine la Rete 2 (Tab. 6.5) ha ottenuto risultati inferiori rispetto alle altre considerate, con un RMSE di  $417.8N$  e una deviazione standard degli errori relativi di 0.31.



**Figura 7.9:** Distribuzione degli errori percentuali del picco di forza, con le reti CNN.

Allo scopo di ridurre ulteriormente l'errore associato alle predizioni, è stata valutata una rete CNN di tipo Efficient Net b0, tale rete in genere è molto performante nel riconoscimento di immagini complesse, e generalmente si può trovare online gratuitamente preaddestrata [63]. Ossia presenta pesi e bias già in una configurazione ottimale, in modo da riconoscere un gran numero di immagini. In questo caso, è stata valutata la struttura di tale rete, effettuando un nuovo addestramento per la predizione della forza di impatto. Il processo di training risulta molto oneroso, in quanto, rispetto alle rete considerate finora, ha una struttura molto più complessa, con un numero elevato di layer e filtri. Lo scopo è quello di comparare le prestazioni di una rete molto più complessa con quelle osservate precedentemente. La rete è stata adeguatamente modificata inserendo un layer completamente connesso e un layer di regressione, per adeguarla al problema di regressione. Sono stati effettuati due addestramenti per questo tipo di CNN. Ottenendo nel primo caso un RMSE di  $419.3N$  e con una deviazione standard degli errori relativi pari a 0.29, mentre nel secondo caso un RMSE di  $312.0N$  e una deviazione standard pari a 0.27. Risulta evidente che nonostante, la rete sia molto più complessa non si evidenzino particolari effetti sull'RMSE; inoltre, si può notare come le performance per questo genere di problema siano legate, non tanto alla complessità della rete, ma alle caratteristiche del problema e alla variabilità intrinseca dei parametri iniziali delle reti.

### 7.2.2 Predizione dell'angolo $\phi$

La predizione dell'angolo  $\phi$  nel piano ha evidenziato diverse difficoltà con le reti adottate. Nonostante ci siano indizi che le reti siano in grado di riconoscere dei pattern nei dati, ciò non garantisce una corretta ricostruzione di tali angoli.

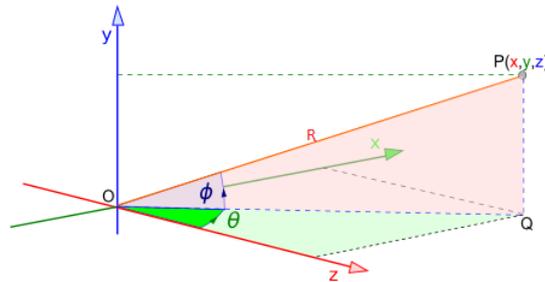


Figura 7.10: Angoli usati.

Nel caso delle reti neurali artificiali, il processo di ottimizzazione ha garantito risultati migliori con la configurazione a 3 layer di rispettivamente 10, 40 e 8 neuroni. L'errore medio risulta essere di  $1.6^\circ$  con un RMSE di  $14.7^\circ$ , il che rappresenta una buona distribuzione rispetto ai valori corretti. Tuttavia, in Figura 7.11 risultano evidenti le difficoltà delle reti, in quanto la distribuzione dei valori predetti si concentra prevalentemente nei valori intermedi del range da predire, non superando l'errore massimo di  $43.6^\circ$ .

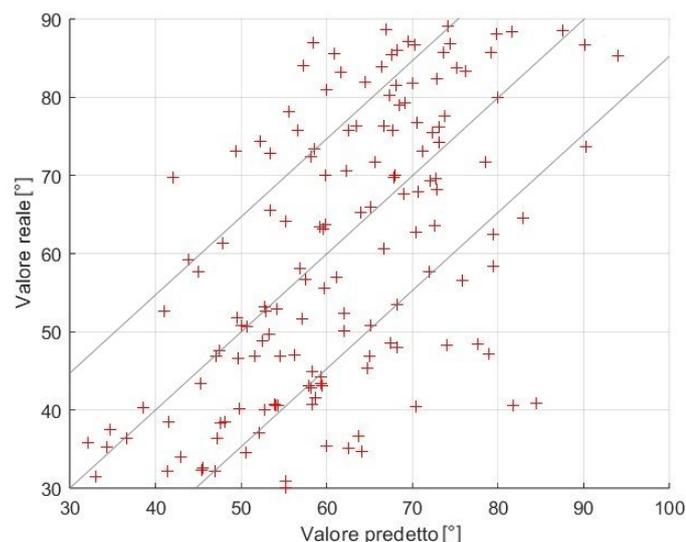
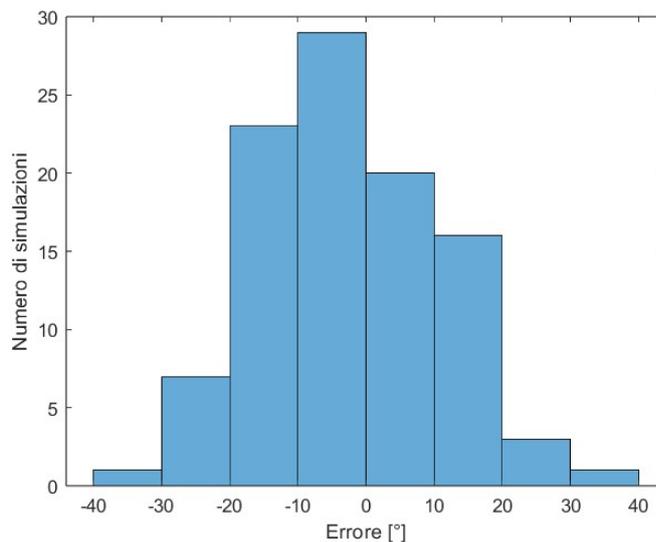


Figura 7.11: Grafico in cui si confrontano i valori di  $\phi$  predetti con quelli reali nel set di test, con la rete 10-40-8. La linea diagonale centrale rappresenta i risultati ideali, mentre le altre 2, identificano un range di errore di  $\pm 15^\circ$ .

L'utilizzo di reti ensemble ha mantenuto l'RMSE all'incirca uguale, pari a  $15.1^\circ$ . Tuttavia, sono risultate di poco migliori, riducendo l'errore medio a  $0.4^\circ$  e l'errore massimo che passa da  $43.6^\circ$  a  $29.7^\circ$ .

Le reti CNN hanno garantito risultati, di poco migliori di quelli delle reti neurali artificiali. C'è un lieve miglioramento dell'RMSE, che si riduce a  $14.0^\circ$ ; mentre la media di  $-2.2^\circ$  e l'errore massimo di  $39.1^\circ$ , migliorano rispetto alle ANN ma non alle reti ensemble. Gli errori presentano una distribuzione gaussiana piuttosto ampia, come evidenziato in Figura 7.12.



**Figura 7.12:** Distribuzione degli errori dell'angolo  $\phi$ , con la rete CNN, Rete 2.

Per migliorare le predizioni di  $\phi$  è stato valutato un inserimento alternativo dei segnali negli Array4D in input alle CNN. Con l'obiettivo di facilitare le reti convoluzionali a ridurre l'errore associato alle predizioni. Tale disposizione innovativa si basa sul concetto di somma di ampiezze, in modo che i colori delle immagini presentino una suddivisione alternativa da quella presentata precedentemente. La nuova disposizione mantiene lo stesso schema sulla disposizione dei sensori, tuttavia applica una trasformazione ai segnali in modo che questi non siano più suddivisi in misure dell'asse X nel colore rosso, Y blu e Z verde; bensì nel seguente modo:

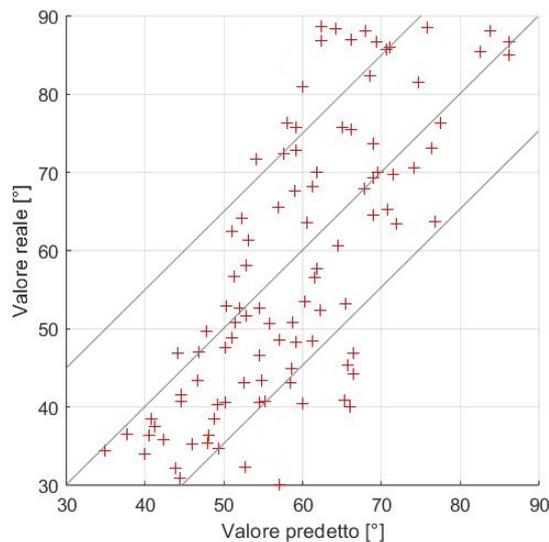
- Il colore rosso rappresenta lo spostamento assoluto al quadrato del sensore, e si ottiene sommando i quadrati delle ampiezze dei 3 assi misurati.

- Il colore verde rappresenta lo spostamento assoluto al quadrato del sensore misurato nel piano, e si ottiene sommando i quadrati delle ampiezze dei segnali lungo gli assi nel piano (X e Z).
- Il colore blu rappresenta il quadrato delle ampiezze misurate in direzione fuori dal piano (Y).

Questa nuova combinazione dei dati in input, segue il principio logico che per la rete convoluzionale sia più semplice identificare caratteristiche legate all'angolo  $\phi$  se i segnali vengono inseriti in modo tale da rendere evidente lo spostamento assoluto, lo spostamento nel piano e fuori dal piano. Tale nuova normalizzazione ha ridotto l'RMSE a  $13.5^\circ$  e la media a  $-1.5^\circ$ , migliorando di poco le previsioni ai bassi angoli, ma comunque non restituendo risultati che si possono ritenere risolutivi.

Rete	RMSE [°]	Err. medio [°]
ANN 10-40-8	14.7	1.6
ANN Ensemble	15.1	0.4
CNN Rete 2	14.0	-2.2
CNN Rete 2 (nuova normalizzazione)	13.5	-1.5

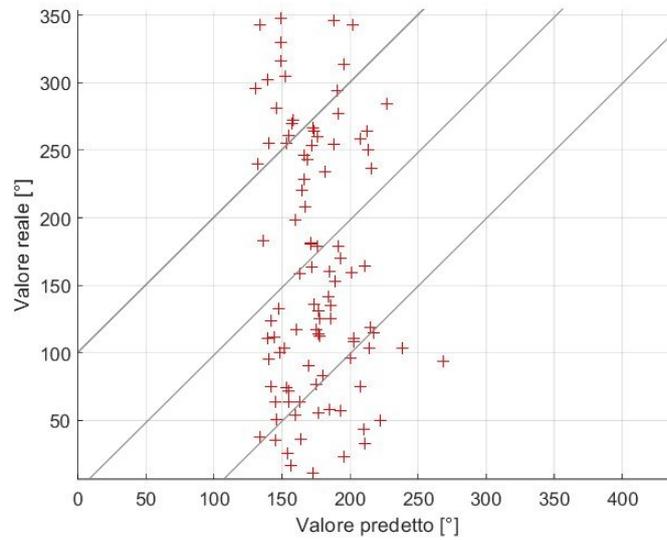
**Tabella 7.6:** Prestazioni delle reti adottate per la determinazione dell'angolo  $\theta$  degli impatti centrali. La rete ANN presenta la configurazione 10-40-8, mentre la CNN adottata presenta la struttura della Rete 2 (Tab. 6.5).



**Figura 7.13:** Grafico in cui si confrontano i valori di  $\phi$  predetti con quelli reali nel set di test, con la Rete 2 con la rinormalizzazione. La linea diagonale centrale rappresenta i risultati ideali, mentre le altre 2, identificano un range di errore di  $\pm 15^\circ$ .

### 7.2.3 Predizione dell'angolo $\theta$

Le predizioni dell'angolo nel piano  $\theta$  non hanno garantito un buon esito con le reti neurali artificiali e quelle convoluzionali. Le reti, infatti, non sono riuscite a ricostruire questo angolo di impatto, generando dei risultati non esprimibili con un andamento gaussiano degli errori. Ciò si traduce nella incapacità di caratterizzare tale angolo.



**Figura 7.14:** Distribuzione degli errori dell'angolo  $\theta$ , con le reti CNN. La linea diagonale centrale rappresenta i risultati ideali, mentre le altre 2, identificano un range di errore di  $\pm 100^\circ$ .

# Capitolo 8

## Conclusioni

I materiali compositi, introdotti nel settore aerospaziale, hanno assunto un ruolo sempre più rilevante nell'ambito ingegneristico e strutturale. Tale tendenza deriva dai numerosi vantaggi, tra cui spiccano le prestazioni meccaniche specifiche elevate (tra cui elevata resistenza e rigidità specifica e ottima resistenza ai cicli a fatica), che consentono di realizzare strutture più leggere portando ad un eventuale risparmio di carburante durante la vita operativa del velivolo. Tuttavia, l'adozione di questi materiali comporta criticità legate ai fenomeni di danneggiamento e ai costi di manutenzione. Durante il servizio, un velivolo può subire impatti di varia natura, come detriti, collisioni con uccelli, grandine o la caduta di attrezzi durante la manutenzione. Questi eventi possono provocare danni BVID, ossia non identificabili attraverso una semplice ispezione, comportando un incremento nei costi di manutenzione per garantirne la sicurezza. Le problematiche associate all'identificazione di tali danni si traducono in una conseguente limitazione nell'uso di tali materiali. Una possibile risoluzione consiste nell'implementazione di tecniche di *structural health monitoring*. Esse consistono in varie metodologie per il riconoscimento dei danni, in modo tale da rendere più immediata l'identificazione di danni BVID, e ridurre conseguentemente il costo e i tempi di manutenzione.

In questa tesi, è stata ampliata la ricerca effettuata in [1] e [2] su una tecnica di monitoraggio strutturale *data-driven* di tipo passivo. Tale tecnica si basa sulla ricostruzione del picco di forza che si verifica durante un impatto, in quanto è possibile confrontarlo con il picco di forza teorico che può causare la delaminazione. Le reti neurali analizzano i segnali di sensori disposti sulla superficie, misurandone ad esempio lo spostamento. Le reti così possono stimare la forza di picco e confrontarla con quella teorica di delaminazione del pannello; in

questo modo è possibile identificare un pannello potenzialmente danneggiato e procedere con un'ispezione più dettagliata. Tale metodologia viene implementata nel caso di impatti inclinati, in quanto, in questo caso l'approccio presentato in [2] non si è rivelato efficace nel predire la forza massima ed in generale questa condizione di carico risulta poco approfondita in letteratura. A tale scopo si utilizza un approccio basato sul *machine learning*, adottando reti neurali, in quanto risultano particolarmente adatte a questo genere di problema. Le reti neurali sono in grado di imparare caratteristiche complesse con un elevato grado di non linearità, come quelle presenti nel problema studiato, quali: la geometria del modello, le caratteristiche anisotrope del materiale, la presenza di attrito e i grandi spostamenti durante l'impatto. Le reti neurali, pur senza conoscere tutti i dettagli del processo, apprendono efficacemente dai dati di addestramento e generalizzano il problema per fare previsioni in nuove condizioni. Sono state adottate due tipologie di reti neurali: le reti neurali artificiali *feed forward* e le reti convoluzionali.

I numerosi dati necessari all'addestramento delle reti neurali sono stati ricavati da 1800 simulazioni effettuate con il software FEM Abaqus, di cui il modello adottato è ampiamente descritto nel quinto capitolo. L'obiettivo principale della tesi è di indagare la possibilità di predire correttamente il picco di forza che si sviluppa negli impatti inclinati poiché in letteratura non sono state trovate ricerche pregresse per questo genere di impatti. Questa tesi si presenta come una ricerca preliminare per l'implementazione di future tecnica SHM reali. Per questo motivo, il nuovo modello adottato riprende quello in [2], variando la dimensione della mesh e rimuovendo i criteri di rottura. L'assenza dei modelli di danneggiamento del pannello è un'ipotesi accettabile in questo caso, poiché gli impatti indagati non generavano forze di impatto superiori a quelle teoriche di delaminazione, e nei test effettuati in condizioni massime con il modello "Fine" non erano stati evidenziati danneggiamenti. Lo sviluppo del caso reale invece, avrebbe richiesto un modello più complesso, che presenti la delaminazione e con una mesh più fitta. Un modello così dettagliato tuttavia avrebbe richiesto risorse di calcolo maggiori, non compatibili con quelle disponibili, e avrebbe reso difficile sviluppare un numero sufficiente di simulazioni per ottenere risultati accettabili. Infatti, adottando queste semplificazioni per il modello in Abaqus, il tempo si è ridotto del 54% rispetto a [2].

La tesi ha confermato l'obiettivo principale, di determinare il picco della forza di impatto con una buona precisione. Le reti CNN e ANN hanno entrambe ga-

rantito risultati accettabili, sebbene l'incertezza sia ancora migliorabile, in quanto superiore rispetto a quella che si ottiene per gli impatti perpendicolari studiati in [2]. Dai test sul valore di forza massima ottenuti con le CNN (Fig. 6.9), si evidenzia che l'aumento del numero di simulazioni è risultato molto efficace ai fini dell'accuratezza delle predizioni. Tuttavia è importante notare che incrementando troppo il numero di simulazioni, c'è il rischio di vanificare i vantaggi delle reti neurali.

Si è osservato inoltre la dipendenza fra le predizioni delle reti e il numero e la disposizione dei sensori. Non sempre l'incremento di informazioni negli input delle reti ha garantito risultati migliori. Si è osservato infatti che una rete con solo il segnale di spostamento massimo di 24 sensori, ha garantito risultati migliori di quelli ottenuti utilizzando anche le informazioni di tempo, ottenendo un RMSE del 19.3% inferiore. Adottando invece in input alle reti la matrice contenente sia lo spostamento massimo che il tempo d'arrivo dei segnali l'accuratezza delle predizioni incrementa sostanzialmente all'aumentare del numero di sensori. Tanto che in questo caso l'uso di 40 sensori, invece di 24, garantisce una riduzione del 50.1% dell'RMSE.

Le reti neurali convoluzionali, invece, presentano un netto miglioramento delle performance all'aumentare del numero di sensori usati. Esse offrono risultati eccellenti in termini di prestazioni, ma sono fortemente dipendenti dalla struttura scelta per la rete. È stato quindi necessario ottimizzare accuratamente la scelta dei layer e dei rispettivi parametri in base ai dati e alla complessità del problema. Questo processo si è rivelato più complesso rispetto alle reti ANN, che avevano il vantaggio di poter trovare la struttura ottimale variando in modo iterativo il numero di neuroni. La migliore CNN analizzata per la determinazione del picco della forza di impatto nel piano è la Rete 1 (Tab. 6.4). Ha presentato una ottima distribuzione degli errori, con errori massimi contenuti e un RMSE è pari a  $223.7N$ . Le CNN sono risultate vantaggiose, non tanto per il miglioramento dei risultati in termini di RMSE, ma per l'adattabilità nelle predizioni adottando input contenenti molte più informazioni. Infatti a differenza delle ANN, le CNN non presentavano i dati in input organizzati, con i valori di spostamento massimi già individuati, ma presentavano i dati grezzi dei sensori. Le tecniche di normalizzazione dei dati in input alle CNN, tuttavia, risultano utili a migliorarne ulteriormente le predizioni.

La rete CNN Efficient Net B0, non è risultata particolarmente vantaggiosa. Ha garantito dei risultati accettabili, ma non buoni quanto alle altre reti utilizzate,

presentando tuttavia dei tempi di addestramento molto più lunghi, evidenziando che l'utilizzo di strutture di CNN più complesse (con più layer) non avrebbero garantito risultati migliori. Mentre il picco di forza risulta predetto con una precisione accettabile ai fini del problema, gli angoli di impatto  $\phi$  e  $\theta$  hanno generato diverse difficoltà nella loro caratterizzazione.

Per l'angolo  $\phi$ , è stato possibile osservare dei miglioramenti in termini di predizioni, ma con un range di errori troppo grande per essere considerato valido. L'utilizzo di tecniche ensemble ha permesso di ridurre gli errori massimi del 31.8% rispetto alla sola rete neurale artificiale. Le CNN hanno fornito risultati simili, ma non definitivi, incrementando di poco la loro efficacia attraverso la redistribuzione dei dati nell'*Array4D*. In futuro, sarà essenziale esplorare diverse distribuzioni dei dati o esaminare ulteriori informazioni per migliorare le previsioni.

Per l'angolo  $\theta$ , anche se le reti hanno presentato ridotte capacità di predizione durante gli impatti centrali, nel piano non hanno garantito alcuna capacità predittiva. Ciò si traduce nell'incapacità sia delle reti ANN che delle CNN considerate in questa tesi, di ricostruire questo angolo di impatto.

In conclusione, per migliorare le previsioni delle reti sono necessari ulteriori indagini. È importante considerare l'utilizzo di dati diversi, come le deformazioni o le onde acustiche. Inoltre, è necessario implementare dei modelli di danneggiamento del pannello simulato per verificarne gli effetti nei dati ottenuti dalle simulazioni. Infine, sarà fondamentale procedere con un confronto sperimentale, effettuando test su pannelli reali. Altri aspetti di interesse potrebbero includere lo studio delle risposte del pannello a danni preesistenti e la valutazione dell'impatto di eventi simultanei.

# Bibliografia

- [1] Cappellini L., *Algoritmi per la determinazione di posizione ed intensità di un impatto su strutture composite*. Tesi di laurea magistrale in Ingegneria Aerospaziale, Padova, 2017.
- [2] Giacomini D., *Caratterizzazione degli impatti su pannelli in materiale composito mediante reti neurali*. Tesi di laurea magistrale in Ingegneria Aerospaziale, Padova, 2023.
- [3] Ghadarah N., Ayre D., *A Review on Acoustic Emission Testing for Structural Health Monitoring of Polymer-Based Composites*. *Sensors*, 23, 6945, 2023.
- [4] Chaupal P., Rajendran P., *A review on recent developments in vibration-based damage identification methods for laminated composite structures: 2010–2022*. *Composite Structures*, 311, 116809, 2023.
- [5] Hassani S., Dackermann U., *A Systematic Review of Optimization Algorithms for Structural Health Monitoring and Optimal Sensor Placement*. *Sensors*, 23, 3293, 2023.
- [6] Ribeiro Junior R.F., Gomes G.F., *On the Use of Machine Learning for Damage Assessment in Composite Structures: A Review*. *Appl Compos Mater*, 31, Pages 1–37, 2024.
- [7] Kaw A. K., *Mechanics of Composite Materials second edition*. Taylor and Francis Group, 2006.
- [8] Ren F., Giannakeas I. N., Sharif Khodaei Z., Ferri Aliabadi M.H., *Theoretical and experimental investigation of guided wave temperature compensation for composite structures with different thicknesses*. *Mechanical Systems and Signal Processing*, 200, 110594, 2023.

- [9] de Sá Rodrigues F., Giannakeas I. N., Sharif Khodaei Z., Ferri Aliabadi M.H., *Probability based damage detection on a composite fuselage panel based on large data set of guided wave signals*. NDT & E International, 139, 102924, 2023.
- [10] Giannakeas I. N., Mazaheri F., Bacarreza O., Sharif Khodaei Z., Ferri Aliabadi M.H. *Probabilistic residual strength assessment of smart composite aircraft panels using guided waves*. Reliability Engineering & System Safety, 237, 109338, 2023.
- [11] Jang Y.-J., Kim H.-J., Kim H.-G., Kang K.-W.: *Identification of debonding damage at spar capshear web joints by artificial neural network using natural frequency relevant key features of composite wind turbine blades*. Appl. Sci. 11(12), 5327, 2021.
- [12] Tran-Ngoc H., Khatir S., Ho-Khac H., De Roeck G., Bui-Tien T., Wahab M.A.: *Efficient artificial neural networks based on a hybrid metaheuristic optimization algorithm for damage detection in laminated composite structures*. Compos. Struct. 262, 113339, 2021.
- [13] Daniel I.M., *Failure of Composite Materials*. Strain, 43, Pages 4-12. 2007.
- [14] A.C. Orifici, I. Herszberg, R.S. Thomson, *Review of methodologies for composite material modelling incorporating failure*. Composite Structures, 86, Issues 1–3, Pages 194-210, 2008.
- [15] Olsson R., *Composite Mechanics & Laminate Theory*. department of Aeronautics, Imperial College, 2006.
- [16] Bishop C. M., *Pattern Recognition and Machine Learning*. Springer, 2006.
- [17] Rashka S., *Machine Learning con Python*. APOGEO, 2015.
- [18] Qing X., Li W., Wang, Y., Sun H., *Piezoelectric Transducer-Based Structural Health Monitoring for Aircraft Applications*. Sensors, 19, 545, 2019.
- [19] C.Bouvet C., Rivallant S., *2-Damage tolerance of composite structures under low-velocity impact*. Dynamic Deformation, Damage and Fracture in Composite Materials and Structures, Pages 7–33, Woodhead Publishing, 2016.

- [20] Olsson R., *Mass criterion for wave controlled impact response of composite plates*. Composites Part A: Applied Science and Manufacturing, 31(8), Pages 879-887, 2000
- [21] Park J., Chang F.-K., *System Identification Method for Monitoring Impact Events*. Smart Structures and Materials: Smart Sensor Technology and Measurement Systems, 5758, 2005
- [22] Tabian I., Fu H., Sharif Khodaei Z., *A Convolutional Neural Network for Impact Detection and Characterization of Complex Composite Structures*. Sensors 19, 22, 4933.
- [23] Sarego G., Zaccariotto M., Galvanetto U. *Artificial neural networks for impact force reconstruction on composite plates and relevant uncertainty propagation*. IEEE Aerospace and Electronic Systems Magazine, vol. 33, 8, Pages 38-47, 2018.
- [24] Thiene M., Galvanetto U., *Impact location in composite plates using proper orthogonal decomposition*, *Mechanics Research Communications*. 64, Pages 1-7, 2015.
- [25] Hashin, Z., *Failure Criteria for Unidirectional Fiber Composites*. ASME. J. Appl. Mech., 47(2), Pages 329–334, 1980.
- [26] Song Z., Luong S., Whisler D., Kim H., *Honeycomb core failure mechanism of CFRP/Nomex sandwich panel under multi-angle impact of hail ice*. International Journal of Impact Engineering, 150, 103817, 2021.
- [27] Aloisi E., *Studio e caratterizzazione della delaminazione in strutture in materiale composito tramite reti neurali*. Tesi di laurea magistrale in Ingegneria Aerospaziale, Padova 2023.
- [28] Fotouhi S., Jalalvand M., Wisnom M. R., Fotouhi M., *Smart hybrid composite sensor technology to enhance the detection of low energy impact damage in composite structures*. Composites Part A: Applied Science and Manufacturing, 172, 107595, 2023.
- [29] Nassir N. A., Gharkan M. R., *Impact response of composite laminates based on epoxy and glass fibre*. Materials Today: Proceedings, 42, Part 5, Pages 1901-1907, 2021.

- [30] Giurgiutiu V., *17 - Structural health monitoring (SHM) of aerospace composites*. Editor(s): Philip Irving, Constantinos Soutis, In Woodhead Publishing Series in Composites Science and Engineering, Polymer Composites in the Aerospace Industry (Second Edition), Woodhead Publishing, Pages 491-558, 2020.
- [31] Faggiani A., Falzon B.G., *Predicting low-velocity impact damage on a stiffened composite panel*, Composites Part A: Applied Science and Manufacturing, 41, Issue 6, Pages 737-749, 2010,
- [32] Thiene M., Sharif Khodaei Z., Ferri Aliabadi M.H., *Optimal sensor placement for maximum area coverage (MAC) for damage localization in composite structures*. Smart Materials and Structures, 25, 095037, 2016
- [33] Mallardo V., Ferri Aliabadi M.H., Sharif Khodaei Z.S. *Optimal sensor positioning for impact localization in smart composite panels*. Journal of Intelligent Material Systems and Structures, 24(5), Pages 559-573, 2013.
- [34] Sharif Khodaei Z., Ghajari M., Ferri Aliabadi M.H., *Determination of impact location on composite stiffened panels*. Smart Materials and Structures, 21, 105026, 2012.
- [35] Demuth H. Beale M., *Neural Network Toolbox™ User's Guide* (online). 2015. <https://api.semanticscholar.org/CorpusID:61288267>
- [36] Hagan M.T., Demuth H.B., Beale M.H., De Jesus O., *Neural Network Design*. 2nd Edition, Martin Hagan, 2014.
- [37] Sattarifar A., Nestorović T., *Damage localization and characterization using one-dimensional convolutional neural network and a sparse network of transducers*. Engineering Applications of Artificial Intelligence, 115, 105273, 2022.
- [38] De Oliveira M.A., Monteiro, A.V., Vieira Filho J., *A New Structural Health Monitoring Strategy Based on PZT Sensors and Convolutional Neural Network*, Sensors, 18(9), 2955, 2018.
- [39] Tang W., Long G., Liu L., Zhou T., Blumenstein M., Jiang J., *Omni-Scale CNNs: a simple and effective kernel size configuration for time series classification*. ArXiv:2002.10061 [cs.LG], 2022.

- [40] Megson T.H.G., *Aircraft Structures for Engineering Students*. 6th edition, Oxford, Elsevier, 2017.
- [41] Gnedin N.Y., Semenov V.A., Kravtsov A.V., *Enforcing the Courant–Friedrichs–Lewy condition in explicitly conservative local time stepping schemes*. Journal of Computational Physics, 359, Pages 93-105, 2018.
- [42] Azuara G., Ruiz M., Barrera E. *Damage Localization in Composite Plates Using Wavelet Transform and 2-D Convolutional Neural Networks*. Sensors, 21, 5825, 2021.
- [43] Saadatmorad M., Jafari-Talookolaei R.-A., Pashaei M.-H., Khatir S., *Damage detection on rectangular laminated composite plates using wavelet based convolutional neural network technique*. Composite Structures, 278, 114656, 2021.
- [44] Jollivet T., Peyrac C., Lefebvre F., *Damage of Composite Materials*. Procedia Engineering, 66, Pages 746-758, 2013.
- [45] Zhang X., Chen Y., Hu J., *Recent advances in the development of aerospace materials*, Progress in Aerospace Sciences, 97, Pages 22-34, 2018.
- [46] Olsson R., *Composite Mechanics & Laminate Theory*. Department of Aeronautics, Imperial College, 2006.
- [47] Aly N. M. *A review on utilization of textile composites in transportation towards sustainability*. IOP Conference Series Materials Science and Engineering 254(4), 042002, 2017
- [48] Olsson R. *Analytical prediction of large mass impact damage in composite laminates*. Composites Part A: Applied Science and Manufacturing, 32, 9, Pages 1207-1215, 2001.
- [49] Abdullah S. I. B., *Damage and Failure in Composite Structures*. Impact Studies of Composite Materials. Composites Science and Technology, Springer, Singapore, 2021.
- [50] Johnson E. R., *Aerospace structures*. (version 0.1), 2022.
- [51] Beale M., Demuth H., *Neural Network Toolbox User's Guide*. The MathWorks, Inc. 2002.

- [52] Goodfellow I., Bengio Y., Courville A., *Deep learning*(online). MIT Press, 2016.  
[https://www.deeplearningbook.org/lecture\\_slides.html](https://www.deeplearningbook.org/lecture_slides.html).
- [53] L. Grippo, M. Sciandrone, *Metodi di ottimizzazione per le reti neurali* (online).  
<https://www.diag.uniroma1.it/~lucidi/didattica/Reti-Neurali-1.pdf>
- [54] Zhao B., Zhang Y., Liu Q., Qing X., *Impact monitoring of large size complex metal structures based on sparse sensor array and transfer learning*. Ultrasonics, Volume 140, 107305, 2024.
- [55] Brilliant.org, *Brilliant math and science wiki* (online). 2020.  
<https://brilliant.org/wiki/convolutional-neural-network/>.
- [56] Ławryńczuk M. *Input convex neural networks in nonlinear predictive control: A multi-model approach*. Neurocomputing 513, Pages 273-293, 2022.
- [57] Bishop C., *Neural Networks for Pattern Recognition*. Clarendon, Oxford, U.K., 1995.
- [58] Olsson R., *Closed form prediction of peak load and delamination onset under small mass impact*. Composite Structures 59, Pages 341–349, 2003.
- [59] Mikulik Z., Haase P., *Composite Damage Metrics and Inspection. EA-SA.2010.C13 Final Report*. Bishop GmbH - Aeronautical Engineers, 2012.
- [60] Tan M., Le Q. V., *EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks*. ArXiv:1905.11946 [cs.LG], 2020.
- [61] mathworks.com, *Butterworth filter design* (online).  
<https://it.mathworks.com/help/signal/ref/butter.html>.
- [62] Singh S., *Cousins of artificial intelligence* (online).  
<https://towardsdatascience.com/cousins-of-artificial-intelligence-dda4edc27b55>, 2018.
- [63] mathworks.com, *Deep Learning Toolbox™ Model for EfficientNet-b0 Network* (online).

<https://it.mathworks.com/matlabcentral/fileexchange/80392-deep-learning-toolboxtm-model-for-efficientnet-b0-network>

- [64] Seydel R., Chang F.K., *Impact identification of stiffened composite panels: I. System development*. Smart Materials and Structures 10(2), Pages 354-369, 2001.