




UNIVERSITÀ DEGLI STUDI DI CAGLIARI

FACOLTA' DI INGEGNERIA

Dipartimento di Ingegneria Elettrica ed Elettronica

Dottorato in Ingegneria Industriale

CICLO XVII



**TECNICHE DI SOFT COMPUTING PER LA CLASSIFICAZIONE E LA
PREDIZIONE DI DISRUZIONI AL JET**

Tutor:

Prof.ssa Ing. Alessandra Fanni

Tesi di Dottorato di:

Ing. Maria Katuscia Zedda

**Tecniche di Soft Computing per la
Classificazione e la Predizione di Disruzioni al
JET**

INTRODUZIONE

L'interesse per la fusione nucleare è cresciuto in maniera considerevole in questi ultimi decenni, in considerazione di due importanti fattori:

- ✓ La sempre più pressante richiesta di energie che rappresentino una valida alternativa a quelle di origine fossile;
- ✓ Le enormi quantità di energia che un successo in questo campo consentirebbe di produrre.

Nel mondo esistono alcune macchine sperimentali. Quella di dimensioni maggiori è il JET (Joint European Torus) sito in Culham (Oxford, UK), che è considerato il prototipo per i reattori di prossima generazione.

Nei reattori tipo JET si studia la produzione di energia da fusione nucleare calda mediante il plasma, quarto stato della materia.

La perdita improvvisa del confinamento magnetico del plasma, conosciuta come 'disruzione', rappresenta al momento, uno dei maggiori ostacoli allo sviluppo dei reattori ed è un rischio considerevole per la sicurezza dei reattori di grandi dimensioni come il JET. Durante un fenomeno disruttivo l'energia immagazzinata nel plasma viene trasferita alla struttura del reattore nell'arco di pochi millisecondi, inducendo delle forze che, in reattori delle dimensioni del JET, possono raggiungere diversi MegaNewton.

Questo problema diventa ancora più pressante per i reattori di prossima generazione, come ITER. Infatti le macchine sperimentali esistenti al momento sono state costruite allo scopo di migliorare le tecniche di produzione di energia e le prestazioni del processo, ma anche per approfondire alcuni aspetti della fisica dei plasmi, tra cui sicuramente il fenomeno, ancora non completamente compreso, delle disruzioni. La struttura della macchina è quindi stata dimensionata per sopportare i carichi termici e meccanici a cui essa è soggetta durante questo tipo di fenomeno. Al contrario, i reattori di prossima generazione come ITER, tuttora in fase di progetto, saranno destinati non allo studio del plasma, ma per dimostrare la fattibilità della produzione di energia per

fusione e la loro struttura, per vincoli progettuali, potrà sopportare solo un numero limitato di disruzioni.

I fenomeni che si verificano durante una disruzione non sono ancora completamente conosciuti. Qualche meccanismo precursore è stato identificato e potrebbe essere utilizzato per predire l'approssimarsi di una disruzione; sfortunatamente la generazione di una disruzione è sempre innescata dalla combinazione di molti eventi (alcuni dei quali non completamente individuati), ed allo stato attuale della ricerca, non è disponibile nessun algoritmo in grado di predirle.

In questa tesi, le reti neurali artificiali sono state applicate a differenti problemi legati al fenomeno delle disruzioni nei reattori a fusione nucleare. In particolare, i dati e le informazioni necessarie allo studio derivano dagli esperimenti condotti al JET.

Le reti neurali artificiali sono state ampiamente applicate a problemi reali in diversi ambiti come pattern recognition, processamento dei dati, controllo non lineare, e predizione; sono state inoltre utilizzate nell'ambito delle ricerche di tipo fusionistico, dimostrando di essere uno strumento utile ed affidabile.

In molte applicazioni reali, le reti neurali si sono rivelate la migliore soluzione possibile a problemi in cui o il modello teorico non era conosciuto, oppure si aveva l'esigenza di avere algoritmi semplici per minimizzare il tempo di calcolo, o addirittura entrambe le esigenze, come nel caso preso in esame in questo lavoro.

Sono stati considerati due aspetti diversi delle disruzioni:

- ✓ Classificazione del tipo di disruzione;
- ✓ Predizione dell'approssimarsi di una disruzione durante un esperimento di fusione.

I due sottoproblemi rispondono a due diverse necessità che si presentano durante una normale campagna sperimentale.

Il tool di classificazione automatica, progettato in questa tesi, permette una rapida identificazione del tipo di disruzione, e quindi anche della causa che l'ha generata. Esso consente di ridurre in maniera considerevole i tempi di identificazione della causa di disruzione rispetto al caso di classificazione manuale.

Il tool di predizione dell'approssimarsi di una disruzione consente un utilizzo della macchina in sicurezza, dotandola di una sistema di allarme in grado di individuare fenomeni anomali del plasma che terminerebbe in una disruzione. A questo scopo il tool di predizione è stato implementato in modalità 'real-time'.

Entrambi i tool sono stati realizzati utilizzando varie tecniche neurali, più precisamente sono state utilizzate le Multi Layer Perceptron, le Support Vector Machines e le Self Organizing Maps.

Per migliorare la robustezza e l'affidabilità dei sistemi di classificazione realizzati si è fatto ricorso all'uso dei classificatori multipli. I classificatori multipli combinano, sulla base di opportune regole, l'uscita di diversi classificatori operanti in parallelo.

Lo studio sulla predizione di disruzioni è completato presentando alcune tecniche di Novelty Detection, che consentono di stimare l'affidabilità della risposta del sistema.

Le diverse tecniche applicate allo stesso problema, in particolare, come accennato in precedenza, nell'ambito della classificazione, permettendo un'analisi dei vantaggi e degli svantaggi di una metodologia rispetto all'altra; inoltre, applicando la stessa tecnica neurale, ad esempio le Multi Layer Perceptron, per risolvere problemi sia di classificazione che di predizione si è voluto mettere in luce la versatilità degli approcci proposti.

Nel primo capitolo di questa tesi viene fatta una breve descrizione degli esperimenti di fusione nucleare e viene presentato il reattore nucleare JET, con particolare riferimento ai sistemi diagnostici, ai sistemi di riscaldamento ed ai parametri del plasma che sono citati nei capitoli successivi. L'ultima parte del capitolo uno è dedicata alle disruzioni, ed ai fenomeni osservati durante una disruzione, sono inoltre introdotti alcuni concetti fisici necessari per una maggiore comprensione del problema.

Nel capitolo due si presenta lo stato dell'arte sia per il problema della classificazione di disruzioni, che per quello della predizione.

Nel capitolo tre si introducono le reti neurali e si descrivono i modelli matematici delle architetture utilizzate.

Il capitolo quattro è dedicato alla descrizione del problema della classificazione di disruzioni e viene fornita un'approfondita descrizione del database utilizzato per progettare i sistemi di classificazione.

Nel capitolo cinque si descrivono le prove condotte con le tre diverse tecniche neurali, e si riportano i risultati ottenuti con il metodo di classificazione statistica k-Nearest Neighbour.

Il capitolo sei è dedicato alla presentazione dei classificatori multipli e dei metodi di Fusion Decision utilizzati nella tesi, ed alla presentazione ed al commento dei risultati ottenuti.

Le conclusioni della prima parte della tesi relativa alla classificazione dei diversi tipi di disruzione vengono presentate nel capitolo sette.

La seconda parte della tesi è dedicata al problema della predizione dell'approssimarsi di una disruzione.

Il problema è presentato e contestualizzato nel capitolo otto, dove si descrive anche il database utilizzato.

Il capitolo nove presenta due sistemi per la predizione delle disruzioni ed i relativi risultati. Il primo sistema è stato realizzato con una rete Multi Layer Perceptron addestrata utilizzando la conoscenza del tipo di disruzione. Il secondo sistema è costituito dalla cascata di una Self Organizing Map e di una rete Multi Layer Perceptron ed ha consentito un netto miglioramento delle prestazioni.

Il capitolo dieci è dedicato alla presentazione delle tecniche di Novelty Detection, con un particolare riferimento a quelle di tipo neurale basate sull'uso delle Self-Organizing Maps. Sono infine presentati alcuni risultati preliminari.

Le conclusi di questa seconda parte del lavoro sono riportate nel capitolo undici mentre le conclusioni generali sono presentate nel capitolo dodici.

RINGRAZIAMENTI

Parte di questo lavoro di tesi è stato svolto presso i laboratori Culham (JET).

Desidero ringraziare ogni persona che, direttamente o indirettamente, ha partecipato alla realizzazione e alla stesura del mio lavoro.

Un grazie particolare va a quelle persone che mi hanno fatto conoscere ed amare la ricerca: Prof.ssa Alessandra Fanni, Dr.ssa Barbara Cannas, Dr. Augusto Montisci.

Ringrazio Prof. Piergiorgio Sonato per gli utili consigli ed il supporto dimostrato in questi tre anni di dottorato.

Desidero inoltre ringraziare: Tommaso Bolzonella, Mike Johnson, David Howell, Richard Buttery, Simon Pinches, Tim Hender, Robert Felton, Chris Boswell, Filippo Sartori, Gianmaria De Tommasi, Marco Bigi, Luca Zabeo, Duccio Testa, Luca Garzotti, Mariangela Usai.

Un grazie speciale va a Fabio e alla mia famiglia, per essermi stati vicini in questi 3 anni, ed avermi supportato ed aiutato con infinita pazienza.

Indice

1. La Fusione Nucleare	1
1.1 Il Processo di Fusione	2
1.2 TOKAMAK	4
1.3 Il Joint European Torus.....	6
1.4 Modi di confinamento al JET.....	9
1.5 Il plasma nei TOKAMAK.....	11
1.6 Disruzioni.....	13
1.6.1 Le quattro fasi della disruzione	16
1.7 Sistemi diagnostici	18
2. Stato dell'arte	19
2.1 Stato dell'arte sulle disruzioni.....	19
2.2 Stato dell'arte sulla predizione di disruzioni.....	23
2.2.1 Predizione di precursori della predizione	23
2.2.2 Predizione di disruzioni.....	25
3. Le Reti Neurali Artificiali	27
3.1 Multi Layer Perceptron	29
3.1.1 Error back propagation: algoritmo di apprendimento	30
3.1.2 La generalizzazione con una rete MLP	34
3.1.3 Classificazione con una rete MLP.....	34
3.1.4 Approssimazione di funzioni mediante MLP.....	37
3.2 Support Vector Machines.....	38
3.2.1 Basi teoriche	39
3.2.2 Caso lineare	41
3.2.3 Support Vector Machines non lineari.....	47
3.2.4 Progettazione di una SVM	49
3.3 Self Organizing Maps	50

3.3.1	Algoritmo di apprendimento	52
4.	La Classificazione delle disruzioni	55
4.1	Selezione dei segnali	58
4.2	Selezione del database.....	60
4.2.1	Classi di disruzione	62
4.3	Training Set.....	70
4.4	Selezione del Test Set	70
5.	Approcci alla classificazione e risultati.....	72
5.1	Multi Layer Perceptron	72
5.1.1	Analisi di salienza	76
5.2	Support Vector Machines.....	77
5.2.1	Support Vector Machines- Risultati	78
5.2.2	Analisi del Test Set.....	79
5.2.3	Analisi dei segnali	80
5.3	Self Organizing Maps	81
5.3.1	Self Organizing Maps –Risultati	82
5.4	k-Nearest Neighbour	84
6.	I Sistemi di classificazione multipla	86
6.1	Insiemi di classificatori	87
6.2	Caratteristiche principali di un sistema di classificatori	88
6.3	Progetto del sistema di classificatori multipli	89
6.4	Risultati	90
6.5	Implementazione	93
7.	Classificazione di disruzioni - Conclusioni	94
8.	Predizione delle disruzioni.....	97
8.1	Database	99
9.	Approcci alla predizione e risultati	103
9.1	Approccio basato sulla classe di disruzione.....	103

9.1.1	Modello neurale.....	104
9.1.2	Risultati	107
9.2	Approccio basato sul clustering	108
9.2.1	Il predittore neurale	108
9.2.2	Risultati	112
9.2.3	Confronto sistema di predizione-Soft Stop	117
9.3	Implementazione on-line.....	117
10.	Novelty Detection	118
10.1	Tecniche di Novelty Detection.....	119
10.2	Risultati preliminari	120
11.	Predizione di disruzioni - Conclusioni.....	122
12.	Conclusioni generali	124
	Bibliografia.....	126

Indice delle figure

Figura 1.1: Configurazione magnetica di tipo TOKAMAK	5
Figura 1.2: Schema iniziale della macchina JET	7
Figura 1.3: Diagramma schematico della superficie poloidale (a) in configurazione Limiter (b) in configurazione X-point.....	10
Figura 1.4: Rappresentazione delle superfici di flusso in un plasma.....	12
Figura 1.5: Linee di campo magnetico della superficie $q=2$	12
Figura 1.6: Danni prodotti da una disruzione all'interno del TOKAMAK.....	13
Figura 1.7: Isole magnetiche	15
Figura 1.8: Fasi della disruzione [3]	16
Figura 3.1: Architettura di una rete Multi Layer Perceptron	29
Figura 3.2: Diagramma a blocchi di un classificatore MLP	35
Figura 3.3: Esempio di separazione lineare	43
Figura 3.4: Esempio di caso non separabile linearmente.....	46
Figura 3.5: Mapping dello spazio degli ingressi in uno spazio delle features ad alta dimensionalità	47
Figura 3.6: Istantanea della fase di addestramento di una rete SOM.....	54
Figura 4.1: Sistema di acquisizione dati al JET	58
Figura 4.2: Esempio di disruzione della classe Modo Bloccato	63
Figura 4.3: Esempio di disruzione della classe Densità Limite	64
Figura 4.4: Esempio di disruzione della classe Alta Potenza Radiata	65
Figura 4.5: Esempio di disruzione della classe Instabilità Verticale	66
Figura 4.6: Esempio di disruzione della classe Modo-H/modo-L	68
Figura 4.7: Esempio di disruzione della classe Trasporto Interno	69
Figura 5.1: Uscita del classificatore MLP (Impulso n°52105 - ML).....	74
Figura 5.2: Errori nel Training Set e nel Test Set al variare del numero dei segnali di ingresso	80

Figura 5.3: Mappa SOM	83
Figura 6.1: Classificatore multiplo basato su insiemi	88
Figura 6.2: Schema di un MCS ad architettura parallela	89
Figura 6.3: Confronto delle percentuali di distribuzione fra 129 impulsi classificati e 125 impulsi non classificati.....	92
Figura 6.4: Interfaccia grafica del tool di classificazione implementato al JET.....	93
Figura 8.1: Intervallo in configurazione X-point selezionato	101
Figura 8.2: Impulso buono	102
Figura 9.1: Target della rete per una generica classe di impulsi disrotti e per la classe DL	105
Figura 9.2: Esempio di una SOM.....	109
Figura 9.3: Som dell'impulso 51515.....	111
Figura 9.4: Uscita della rete MLP per l'Impulso 51519	114
Figura 9.5: Uscita della rete MLP per l'Impulso 54209	115
Figura 9.6: Uscita della rete per l'Impulso 54712.....	116
Figura 10.1: Schema del sistema di predizione.....	119

Indice delle Tabelle

Tabella 1-1: Parametri di progetto del JET	8
Tabella 3-1: Alcuni esempi di funzioni di Kernel.....	49
Tabella 4-1: Distribuzione iniziale delle classi di disruzione nel Training Set.....	61
Tabella 4-2: Distribuzione finale delle classi di disruzione nel Training Set	70
Tabella 4-3: Distribuzione delle classi di disruzione nel Test Set	71
Tabella 5-1: Codifica dell'uscita della rete MLP	73
Tabella 5-2: Distribuzione delle classi fra Training Set e Validation Set.....	74
Tabella 5-3: Performance della migliore rete MLP in termini di numero di impulsi non correttamente classificati.....	75
Tabella 5-4: Performance della migliore rete MLP in termini di numero di campioni erroneamente classificati.....	75
Tabella 5-5: Analisi di salienza del Test Set per la migliore rete MLP	76
Tabella 5-6: Distribuzione delle classi fra Training Set e Test Set.....	77
Tabella 5-7: Performance della migliore rete SVM.....	78
Tabella 5-8: Distribuzione degli errori fra le classi della migliore SVM	79
Tabella 5-9: Errori sul Training Set e sul Test Set con set di segnali ridotto	81
Tabella 5-10: Performance della migliore SOM.....	82
Tabella 5-11: Performance del migliore classificatore k-NN	84
Tabella 6-1: Performance del sistema di classificatori multipli.....	91
Tabella 6-2: Percentuali di voto degli impulsi non classificati.....	92
Tabella 9-1: Distribuzioni degli impulsi fra Training Set e Validation Set	105
Tabella 9-2: Performance della rete MLP.....	107
Tabella 9-3: Distribuzione degli impulsi nel Training Set, Validation Set e Test set....	112
Tabella 9-4: Performance del migliore MLP	113
Tabella 9-5: Confronto fra MLP e SS	117

1. LA FUSIONE NUCLEARE

Studi recenti [1] prevedono che il consumo di energia nel mondo è destinato a duplicarsi o addirittura triplicarsi nei prossimi 50 anni. Questo è dovuto principalmente a due fattori: la popolazione mondiale sta aumentando in maniera significativa e parallelamente a questo fenomeno si osserva un aumento della media dei consumi di energia pro-capite, soprattutto in quei paesi dove è più forte la crescita industriale.

Di contro, le scorte di petrolio e di gas naturale si potrebbero esaurire nei prossimi 100 anni.

Ma anche nel caso in cui queste previsioni fossero sbagliate, come da alcune parti viene sostenuto, le conseguenze ambientali legate all'utilizzo di fonti energetiche di origine fossile, in particolare l'aumento di CO₂ nell'aria, rappresentano un fardello per tutta l'umanità.

Al momento la comunità scientifica mondiale è impegnata a trovare diverse soluzioni a questo problema sempre più pressante, come le tecnologie ad Idrogeno, la fissione nucleare o l'energia solare.

Una valida alternativa può essere la fusione termo-nucleare.

La fusione nucleare è una fonte di energia non-inquinante, intrinsecamente sicura, e inesauribile.

Di contro, lo studio della fusione nucleare comporta l'utilizzo di altissima tecnologia, con conseguente impegno di notevoli risorse economiche; lo sviluppo di tale campo di ricerca risulta quindi particolarmente gravoso rispetto a quello relativo ad altre fonti energetiche convenzionali.


1.1 Il Processo di Fusione

La fusione nucleare poggia le sue basi su diverse scoperte nel campo della fisica dell'inizio del 20° secolo, come la legge di equivalenza massa-energia proposta da Einstein e il difetto di massa relativo ad un atomo di Elio e 4 atomi di Idrogeno misurato per la prima volta da Aston. Tuttavia, i principali impulsi in questo campo sono venuti dall'astrofisica e dallo studio dell'energia delle stelle. Già nel primo quarto del 20° secolo i fisici, in particolare Eddington, avevano intuito che l'energia delle stelle fosse generata da un processo di fusione, e nel 1939 Bethe, presentò una prima descrizione qualitativa e quantitativa della produzione di energia nel sole.

Il processo di fusione consiste nell'accorpamento di due nuclei leggeri (ad esempio di Idrogeno) che vanno a costituire un nucleo più pesante, ma di massa inferiore alla somma delle masse iniziali, con conseguente rilascio di energia. Tale energia è ripartita in energia cinetica tra i prodotti della reazione, cioè il nucleo prodotto ed eventualmente neutroni o protoni. Questo rilascio di energia indica che si è passati ad uno stato dei componenti energeticamente più stabile, in quanto per riottenere le particelle iniziali bisognerebbe fornire energia al nucleo che è stato prodotto.


Negli anni cinquanta si erano individuate le reazioni che presentavano le caratteristiche più adatte per ottenere la fusione termonucleare.

La più vantaggiosa da un punto di vista energetico è quella fra gli isotopi due e tre dell'Idrogeno, rispettivamente Deuterio (D) e Trizio (T):



Il Deuterio e il Trizio sono disponibili in grandi quantità sulla terra. Infatti il Deuterio può essere estratto facilmente dall'acqua di mare attraverso una reazione di elettrolisi. Da ogni litro d'acqua possono essere estratti circa 33 mg di Deuterio, che equivalgono a

circa 360 litri di petrolio. Il Trizio, pur essendo presente solo in tracce in natura, è facilmente estraibile con una reazione di fissione da un metallo comune, il Litio (*Li*):



Come si evidenzia dalla (1.1), anche una ridotta quantità di prodotti della fusione è in grado di produrre una notevole quantità di energia.

Affinché la reazione di fusione avvenga, i nuclei atomici devono essere portati ad una distanza molto piccola, devono quindi possedere un'energia sufficiente a vincere la reciproca repulsione elettrostatica (barriera di Coulomb); l'energia cinetica viene fornita riscaldando gli atomi fino a portarli ad un'elevata temperatura, che nel caso della reazione D-T è circa 10 KeV, equivalenti a 100 milioni di gradi Kelvin.

A tali temperature i gas raggiungono lo stato di plasma. Il termine 'materia allo stato di plasma', come in uso nella fisica sin dal 1920, indica il gas ionizzato ovvero con atomi che hanno perso quasi del tutto i loro elettroni. Se forniamo una sufficiente quantità di calore al gas gli elettroni guadagnano energia sufficiente per sfuggire ai loro atomi. Questi atomi, privati di uno o più elettroni, diventano ioni positivi.

Anche se il plasma è formato da elettroni e ioni, e conduce elettricità, a livello macroscopico rimane elettricamente neutro: in quantità misurabili infatti, il numero degli elettroni e degli ioni è uguale. Però, le particelle cariche vengono influenzate sia dai campi elettrici che da quelli magnetici applicati al plasma ed il moto di queste particelle nel plasma, genera a sua volta un flusso elettrico o magnetico al suo interno. Questa complessa serie di interazioni rende il plasma uno stato della materia unico, complesso ed estremamente affascinante. Più del 99 % della materia che compone l'universo si trova allo stato di plasma; ciononostante raramente sul nostro pianeta si trova in natura: l'ambiente elettricamente neutro sulla Terra è infatti una rara eccezione.

Per controllare il plasma alle temperature richieste, sono stati sviluppati due diversi approcci:

- ✓ Confinamento Inerziale;
- ✓ Confinamento Magnetico.

Nel confinamento inerziale, una pastiglia sferoidale, detta ‘pellet’, costituita da una miscela di Deuterio e Trizio, viene irradiata da impulsi di energia molto intensi ma molto brevi, come, ad esempio, un raggio laser, e le condizioni per la fusione vengono raggiunte durante l’implosione del combustibile, prima che il materiale tenda naturalmente ad espandersi.

Nel confinamento magnetico il controllo del plasma viene attuato per mezzo di campi magnetici, che, come visto in precedenza, sono in grado di influenzare la posizione del plasma.

1.2 TOKAMAK

Esistono diversi tipi di confinamento magnetico del plasma, quello che al momento viene considerato il più promettente dalla comunità scientifica internazionale, è il TOKAMAK proposto da Andrey Sakharov e Igor Tamm [2] negli anni cinquanta. Il nome TOKAMAK è un acronimo della parola russa *Toroidalnaya Kamera i Magnitnaya Katushka*, che significa ‘camera toroidale con bobine magnetiche’. Come la parola stessa dice, il TOKAMAK è una camera di forma toroidale, dove le particelle cariche vengono ‘imprigionate’ da delle linee di campo magnetico chiuse.

Il campo magnetico dominante all’interno della camera è un campo magnetico toroidale, B_ϕ , generato da un sistema di bobine opportunamente posizionate. La configurazione a campo puramente toroidale non è però adatta al confinamento di cariche perché queste, in tempi assai rapidi, tenderebbero a migrare verso l’esterno a

causa della velocità di deriva o di drift, impattando così verso la parete interna della camera. Al campo magnetico toroidale è quindi sovrapposto un campo magnetico poloidale, B_θ , il cui scopo non è solo quello di evitare fenomeni di drift, ma anche di controllare la posizione del plasma.




Figura 1.1: Configurazione magnetica di tipo TOKAMAK

In un TOKAMAK, il campo poloidale viene generato da una spirale ideale costituita dal plasma stesso. Affinché ciò avvenga è necessario che tale spirale ideale sia percorsa da una corrente toroidale I_p , cioè che nel plasma si realizzi un moto toroidale di massa di ioni ed elettroni (i due moti hanno ovviamente verso di rotazione opposto). Tale corrente di cariche viene indotta da un circuito magnetico concatenato sia col plasma che con una bobina attraversata da una corrente elettrica variabile. Tutto avviene come se il plasma

costituire il secondario di un trasformatore secondo lo schema in Figura 1.1. Il campo risultante dalla somma del campo toroidale e di quello poloidale avrà quindi delle linee di campo ad andamento elicoidale.

La corrente I_p gioca un'importante ruolo non solo nel confinamento e nel controllo di posizione ma anche nel riscaldamento del plasma. Infatti in un plasma percorso da corrente la temperatura aumenta per effetto ohmico. Tuttavia, giacché la resistività elettrica η , diminuisce all'aumentare della temperatura del plasma, il solo riscaldamento ohmico non è sufficiente per far raggiungere al plasma le temperature richieste per la fusione nucleare [3]. Per questo motivo energie addizionali devono essere fornite dall'esterno.

Per ottenere la corrente indotta I_p , è necessario un flusso magnetico variabile, e quindi una corrente nel primario variabile; inoltre, poiché l'inversione della corrente nel plasma causerebbe una inaccettabile inversione del campo poloidale, è necessario che il flusso e quindi la corrente primaria, varino monotonamente.

Poiché la corrente non può, per ovvi motivi fisici e tecnologici, crescere indefinitamente, è necessario esercire la macchina in maniera pulsata. Gli impulsi di corrente possono avere una durata che va da poche decine di secondi a qualche secondo, a seconda delle dimensioni della macchina.

Obiettivo finale dei TOKAMAK è quello di mantenere la temperatura del plasma abbastanza a lungo da raggiungere il punto di ignizione, intendendo con questo termine l'istante in cui il plasma inizia riscaldarsi con il calore che esso stesso produce, rendendo possibile una produzione continua di energia.

1.3 Il Joint European Torus

Il JET (Joint European Torus) è il reattore a fusione nucleare più grande al mondo. Esso è stato costruito tra il 1978 e il 1999 ed ha prodotto il primo plasma nel giugno del

1983. Nasce dalla collaborazione di 16 paesi europei, sotto gli auspici dell'EURATOM (European Atomic Energy Community). Dal 2000 il programma scientifico e tecnologico viene portato avanti dall' EFDA (European Fusion Development Agreement) mentre la macchina viene gestita per conto dell' EFDA da UKAEA (United Kingdom Atomic Energy Authority).

L'esperimento ha lo scopo di studiare dei sistemi di riscaldamento e di confinamento per plasmi di grandi dimensioni, investigare sulle interazioni plasma-parete del TOKAMAK, e infine analizzare la produzione delle particelle α durante i processi di fusione termo-controllata.

Un'importante caratteristica del JET è quella di esser stato progettato per lavorare in condizioni di prossimità al punto di break-even, cioè il momento in cui l'energia spesa per scaldare il plasma viene completamente bilanciata da quella prodotta dal plasma stesso ($Q=1$).




Figura 1.2: Schema iniziale della macchina JET

Il JET, la cui struttura è rappresentata in Figura 1.2, è in grado di produrre plasmi la cui sezione poloidale ha la forma di una D (D-shape) allo scopo di minimizzare gli stress sulle bobine di campo poloidale. La macchina è stata progettata per realizzare campi magnetici sino a 3.8 T. Negli ultimi anni si sono raggiunte correnti di plasma di 7 MA.

La Tabella 1-1 presenta i parametri originali di progetto.

Parametri del Jet	
Raggio maggiore di plasma	2.96 m
Raggio minore di plasma	2.10 m (verticale) 1.25 m (orizzontale)
Lunghezza degli impulsi al Flat-Top	20 s
Peso del nucleo centrale	2800 t
Potenza delle bobine di campo toroidale	380 MW
Campo magnetico toroidale	3.45 T
Corrente di plasma	4.8 MA
Potenza dei riscaldamenti addizionali	25 MW

Tabella 1-1: Parametri di progetto del JET

Il JET detiene numerosi record in ambito fusionistico, molti dei quali raggiunti durante le campagne sperimentali del 1997 quando per tre mesi sono stati portati avanti gli esperimenti utilizzando come combustibile diverse combinazioni di Deuterio e Trizio. Durante quelle campagne al JET sono stati raggiunti 3 record mondiali:

- ✓ 22MJ di energia di fusione in un impulso;
- ✓ 16 MW di picco di potenza di fusione;
- ✓ un rapporto del 65% fra potenza di fusione prodotta e potenza fornita dall'esterno.

Al JET, (come in tutte le macchine di tipo TOKAMAK), oltre al riscaldamento di tipo ohmico sono installati altri tre tipi di riscaldamento addizionale.

Il sistema di riscaldamento a radio frequenza ioni-ciclotronico ‘Ion Cyclotron Radio Frequency’ (ICRF) che accoppia delle onde elettromagnetiche ad alta potenza all’interno del plasma. Gli ioni vengono accelerati dal campo elettrico delle onde e conseguentemente il plasma si scalda per semplice collisione. Il sistema ICRF ha una capacità di potenza installata di 32 MW per 20 s e le sue frequenze possono variare nei due range, 23-39 MHz e 41-57 MHz così da superare il range di frequenza del campo magnetico e diminuire la possibilità di risonanza.

L’iniezione di particelle neutre, ‘Neutral Beam Injection’ (NBI) rappresenta la seconda maggiore sorgente di riscaldamento con una potenza totale di circa 20 MW per 10 s. Questo sistema immette all’interno del plasma un fascio di particelle neutre. Gli atomi all’interno del plasma, si ionizzano per collisione e trasferiscono la loro energia cinetica al plasma. Gli atomi di Idrogeno, Deuterio, Trizio e Elio possono essere immessi sia in direzione normale al toro che in direzione tangenziale.

Il metodo ‘Lower Hybrid Current Drive’ consiste nell’inviare microonde ad una frequenza di 3.7 GHz, che accelerano gli elettroni del plasma e generano una corrente superiore ai 3 MA. La potenza installata è di circa 10 MW. Lo scopo principale di questo sistema non è in realtà quello di riscaldare il plasma ma di manipolare la distribuzione di velocità degli elettroni.

1.4 Modi di confinamento al JET

In una macchina a confinamento magnetico, il plasma è confinato all’interno di una superficie di flusso magnetico chiusa. Questa superficie è generata dalla combinazione di due campi magnetici, uno dovuto alla corrente che circola in un circuito esterno e l’altro alla corrente che circola nel plasma stesso. Questi campi possono però essere generati soltanto all’interno di un volume ristretto, il cui confine è determinato dall’ultima superficie di flusso chiusa, ‘Last Closed Flux Surface’ (LCFS).

La forma della LCFS è determinata dai campi magnetici applicati. Tuttavia, la superficie magnetica chiusa può essere interrotta da una superficie solida che quindi determina la posizione dell'ultima superficie di flusso chiusa. Tale superficie solida viene comunemente indicata come 'Limiter', e in questo caso si dice che il plasma si trova in configurazione Limiter.

Una configurazione alternativa può essere ottenuta se la superficie chiusa viene interamente determinata dai campi magnetici di modo che, esternamente alla LCFS, il plasma fluisce verso la superficie solida ed eventualmente interagisce con quest'ultima. Questa è la geometria che sta alla base di un TOKAMAK con divertore, che è in grado di generare configurazioni di plasma in 'X-point'.

Le due configurazioni sono rappresentate nella Figura 1.3.

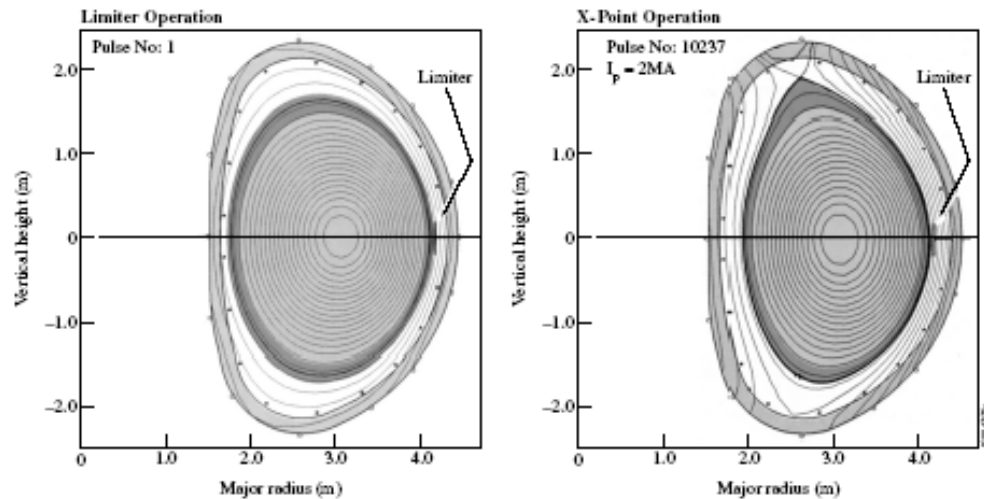


Figura 1.3: Diagramma schematico della superficie poloidale (a) in configurazione Limiter (b) in configurazione X-point

La differenza fondamentale fra le due configurazioni è che nella configurazione Limiter la LCFS viene a contatto con una superficie solida, mentre in X-point, quindi in

presenza del divertore, la superficie solida risulta abbastanza distante dalla LCFS. Entrambe le configurazioni presentano vantaggi e svantaggi, infatti nei plasmi con divertore i plasmi sono più piccoli e la disposizione delle bobine è più complessa rispetto a quella per plasmi in configurazione Limiter. Di contro però, i plasmi in X-point presentano un migliore confinamento e sono meno influenzabili dalla presenza di impurità nel plasma; inoltre, la configurazione Limiter non è in grado di sopportare flussi di calore molto elevati.

E' opinione abbastanza condivisa nella comunità scientifica che i reattori di prossima generazione lavoreranno con plasmi in X-point.

1.5 Il plasma nei TOKAMAK

Il comportamento del plasma suggerisce una analogia tra la dinamica dei plasmi e la dinamica dei fluidi. Lo studio del plasma inteso come fluido, tenendo conto delle sue proprietà magnetiche dà origine al campo della Magneto Idrodinamica (MHD) [4].

Il plasma può essere visto come un fluido confinato in una 'ciambella magnetica' generata dai campi magnetici. Come spiegato nel Par. 1.2, sul plasma agiscono due campi magnetici, B_ϕ e B_θ . La combinazione di questi due campi dà origine alla formazione di superfici di flusso annidate nel plasma, come può essere osservato dalla Figura 1.4, in cui le linee di campo magnetico seguono dei percorsi elicoidali intorno al toro. Questa struttura sta alla base della stabilità del plasma.




Figura 1.4: Rappresentazione delle superfici di flusso in un plasma

Quando le linee di campo girano intorno alla superficie, possono coprire tutta l'area della superficie senza mai passare due volte per lo stesso punto, oppure possono richiudersi su se stesse dopo m rotazioni toroidali e n poloidali, come in Figura 1.5.




Figura 1.5: Linee di campo magnetico della superficie $q=2$

Nella Figura 1.5 le linee di campo e le superfici ad esse associate hanno un fattore di sicurezza, 'safety factor' $q=m/n=2$. Il fattore di sicurezza gioca un ruolo

importantissimo per quel che riguarda la stabilità del plasma. In particolare un fattore di sicurezza più alto implica una maggiore stabilità.

1.6 Disruzioni

Le disruzioni sono eventi drammatici in cui tutta l'energia del plasma viene rilasciata in pochi millisecondi. Ognuno di questi fenomeni può danneggiare seriamente la struttura sia interna che esterna della macchina. Infatti le disruzioni più serie, che avvengono in corrispondenza di elevati valori della corrente di plasma, sottopongono la macchina ad altissime temperature ed a stress meccanici considerevoli, causando dei danni come quelli in Figura 1.6.



Figura 1.6: Danni prodotti da una disruzione all'interno del TOKAMAK

Inoltre, esse rappresentano non solo un grosso problema ma anche un grosso limite per gli esperimenti nell'ambito della fusione. Infatti, allo scopo di evitare le disruzioni è necessario porre dei limiti ai valori dei parametri operativi della macchina, come la densità del plasma o la velocità di salita della corrente, riducendo lo spazio operativo in cui effettuare gli esperimenti.

Purtroppo, al momento, la fisica alla base dell'evento distruttivo non è ancora completamente conosciuta.

E' stato più volte verificato che le superfici con un basso numero razionale di fattore di sicurezza e soprattutto le superfici con $q=2$, rivestono un ruolo molto importante per quel che riguarda le instabilità del plasma.

Le instabilità più frequenti sembra siano causate da un gradiente di corrente. Per esempio, se la densità del plasma aumenta oltre un certo limite, oppure se il plasma non è sufficientemente puro, si osserva un aumento della potenza radiata dal plasma, con una conseguente contrazione della temperatura. Questi fenomeni portano ad un aumento della resistenza nelle regioni più esterne, il cui risultato è un restringimento del canale di corrente. E' l'effetto di questo step di corrente nella superficie $q=2$ che porta a una delle disruzioni più frequenti nelle macchine TOKAMAK, ed in particolare al JET, le cosiddette Densità Limite, 'Density Limit'.

In un altro tipo di disruzione, quelle con basso valore di q 'Low- q ', la superficie $q=2$ viene spostata dalla corrente di plasma verso la parte più esterna del plasma, trovandosi così in una posizione instabile rispetto al gradiente di corrente

Nella pratica si è osservato che una volta che la superficie con $q=2$ si trova in una posizione di instabilità, la formazione delle cosiddette 'isole magnetiche' porta quasi sempre ad un fenomeno distruttivo. Le isole magnetiche, che possono essere considerate i primi precursori delle disruzioni, si formano quando le linee di campo di una superficie instabile interagiscono con le linee di campo delle superfici ad essa limitrofe. Le superfici al di sopra della superficie instabile presentano valori di q più alti di quelli al di

sotto. Perciò la direzione del campo magnetico nelle superfici limitrofe sopra e sotto la superficie instabile è opposta, come si può vedere nella parte alta della Figura 1.7.

Per questo motivo le linee di campo della superficie instabile si spezzano e si ricompongono andando a formare delle isole magnetiche, come si può osservare nella parte bassa della Figura 1.7.




Figura 1.7: Isole magnetiche

Al principio del fenomeno, le isole magnetiche hanno delle dimensioni relativamente ridotte, e ruotano attorno al proprio asse, e attorno all'asse del TOKAMAK, durante questa rotazione altre superfici si connettono con le isole magnetiche aumentando il numero di particelle coinvolte nel fenomeno, e quindi le dimensioni stesse dell'isola magnetica.

Se nel plasma appare più di una canale di isole magnetiche di dimensioni sufficienti, queste possono interagire formando una 'regione di ergodicità'. In queste regioni la struttura delle superfici annidate è completamente distrutta. Questi fenomeni distruggono completamente la struttura del confinamento magnetico e si osserva la disruzione del plasma.

Le disruzioni possono essere causate anche da altri fenomeni, come il contatto del plasma con la parete della camera toroidale, oppure un'instabilità verticale; altre instabilità sono da imputarsi all'iniezione di combustibile nel plasma, etc..

1.6.1 Le quattro fasi della disruzione

I processi fisici coinvolti in una disruzione non sono conosciuti nel dettaglio, ma un'analisi approfondita ha portato a schematizzare la sequenza di eventi che caratterizzano una disruzione in quattro fasi [5], come si può vedere in Figura 1.8.




Figura 1.8: Fasi della disruzione [3]

Fase dei pre-precursori, ‘pre-precursor phase’. In questa fase si osserva una variazione delle condizioni del plasma verso configurazioni più instabili. Questa variazione, relativamente lenta, a volte è molto chiara; si può infatti osservare un chiaro aumento della densità del plasma o un aumento della radiazione del plasma dovuto alla presenza di impurità. Altre volte invece la disruzione avviene senza che cambiamenti significativi nello stato del plasma siano osservabili.

Fase dei precursori, ‘precursor phase’. In questa fase le condizioni del plasma hanno raggiunto un punto critico ed iniziano ad osservarsi delle instabilità MHD, le isole magnetiche, in particolare quelle con modo $m=2$, e la loro successiva crescita. La crescita di queste instabilità non è lineare, ma esse tendono a crescere secondo intervalli di durata variabile fino al momento in cui tutto si blocca; questo non è dovuto al fatto che il sistema ha ritrovato lo stato di stabilità, ma è causato dal fenomeno del Modo Bloccato, ‘Mode-Locking’ [6]. Si sviluppa un Modo Bloccato quando l’ampiezza dell’instabilità è sufficientemente grande da interagire con i conduttori esterni. L’intervallo di tempo durante cui si sviluppa questa crescita varia con il tipo di disruzione e con la dimensione della macchina.

Una volta che le instabilità MHD sono cresciute a sufficienza, viene raggiunto un secondo punto critico. Da questo momento in poi, tutti i fenomeni si svilupperanno molto rapidamente. Infatti durante la fase veloce, ‘fast phase’, si assiste ad un collasso della temperatura centrale in un tempo tipicamente dell’ordine di qualche millisecondo. Questa fase è piuttosto complessa e sono coinvolti diversi processi di trasporto di energia.

Nella fase finale di spegnimento, ‘quench phase’, si assiste ad un rapido decadimento della corrente di plasma. Questo è per lo più causato da un incremento della resistenza dovuto al raffreddamento del plasma stesso. Durante questa fase, in parte per l’effetto ohmico dovuto all’aumento di resistenza, in parte a causa delle correnti indotte nella

macchina, la struttura del TOKAMAK viene esposta a numerosi stress sia di origine meccanica che termica.

1.7 Sistemi diagnostici

Per poter controllare in maniera efficace il plasma è necessario che questo venga costantemente monitorato da un certo numero di sistemi diagnostici.

Di seguito sono indicati quelli al momento presenti al JET.

Le bobine magnetiche ‘pickup coils’ sono montate intorno alla parete interna del TOKAMAK e misurano i campi magnetici. Sono particolarmente utili per monitorare eventuali instabilità MHD.

La potenza radiata del plasma viene invece misurata dalla telecamera bolometrica.

L’emissione ciclotronica di elettroni, ‘Electron cyclotron emission’ (ECE) è misurata da diversi strumenti come l’interferometro o il polychromator o il heterodyne radiometer. Le telecamere a raggi X misurano invece l’emissione di soft X-ray. Alcune volte sono usati l’ECE e le telecamere a raggi X, magari insieme a diagnostiche laser, per determinare il profilo di temperatura del plasma.

Le diagnostiche laser possono essere anche usate per misurare la densità elettronica.

Le impurità vengono monitorate dallo spettrografo.

Questo insieme di strumenti diagnostici permette di avere un’importante set di misure sullo stato del plasma; inoltre, queste misure dirette vengono poi elaborate per calcolare ulteriori parametri.

2. STATO DELL'ARTE

Il fenomeno delle disruzioni è stato osservato per la prima volta nel 1963 da due fisici russi: Gorbunov e Razumova [7].

Da quel momento, gli studi su questo argomento sono stati numerosi [8-38], molti dei quali, incentrati soprattutto sulla descrizione qualitativa dei fenomeni osservati. Nessun articolo però presenta una trattazione teorica in grado di spiegare appieno i complessi fenomeni osservati durante un evento disruttivo; ciò sarebbe stato un utile punto di partenza per l'individuazione di un modello matematico in grado di predire il fenomeno delle disruzioni.

Negli ultimi quindici anni, svariati articoli apparsi in letteratura hanno affrontato il problema della predizione delle disruzioni.

Infatti, se una disruzione viene predetta con sufficiente anticipo, è possibile utilizzare opportuni sistemi in grado di mitigare, se non addirittura evitare, gli effetti disastrosi descritti in precedenza.

Di seguito sono presentati i lavori più rilevanti presenti in letteratura.

2.1 Stato dell'arte sulle disruzioni

L'assenza di un modello teorico sulle disruzioni ha portato la comunità scientifica a cercare di individuare i limiti operativi di un reattore a fusione studiando in maniera approfondita i database disponibili, 'operation-based description' [3]. Sulla base di questi studi sono stati poi individuati alcuni tipi di disruzione ed alcuni limiti operativi.

Nel 1977 Murakami [8] studiando la relazione fra densità del plasma e il problema del confinamento in plasmi ad Idrogeno con solo riscaldamento ohmico, introduce il

parametro che porta il suo nome; il parametro di Murakami si è in seguito rivelato un grandezza particolarmente utile per descrivere gli stati del plasma.

In [9], Hugill presenta il diagramma che da lui prende il nome. Questo diagramma presenta in ascissa il parametro di Murakami e in ordinata l'inverso del fattore di sicurezza nella superficie più esterna del plasma, q_a . Con l'ausilio di questo diagramma è stato possibile verificare che le disruzioni impongono dei limiti operativi sia alle regioni che presentano un basso valore di q_a , sia a quelle con alti valori di densità. Il valore limite della densità varia al variare del riscaldamento addizionale. E' importante sottolineare ancora una volta che questi risultati sono empirici e dipendono fortemente dal tipo di plasma considerato.

Analizzando i dati di numerosi TOKAMAK, in [10] e in [11] Greenwald generalizza i risultati empirici fino a quel momento ottenuti, definendo un valore critico della densità degli elettroni nel plasma in funzione dell'elongazione del plasma stesso e della densità di corrente media in una sezione di plasma.

Nella pratica non è però possibile predire le disruzioni dovute a Densità Limite, sulla base del limite di densità di Greenwald.

Partendo da considerazioni sia teoriche che empiriche sui limiti operativi imposti dalle disruzioni, sono stati individuati e presentati in letteratura alcuni tipi di disruzione.

La lista che segue non vuole e non può essere esaustiva su questo argomento, infatti tanti e tutti di notevole importanza, sono stati i contributi in questo campo.

Una descrizione dei vari aspetti relativi alle disruzioni è stata fatta da Wesson [5] che oltre a descrivere le fasi delle disruzioni, (vedi Cap.2), descrive tre tipi di disruzione: le Densità Limite, Basso Valore di q , e disruzioni causate da Instabilità Verticale (VDE). Le VDE si possono avere solo in presenza di plasmi elongati e sono generalmente dovute al cattivo funzionamento dei sistemi per il controllo di posizione [12] [13]. Infatti il malfunzionamento di questo tipo di controllo causa uno spostamento verticale del plasma. Questo evento non è direttamente una causa di disruzione, ma porta ad una riduzione del fattore di sicurezza q_a , che invece è riconosciuta come causa di disruzione.

In [14] Schuller riassume le conoscenze acquisite sino a quel momento sulle instabilità che possono provocare una disruzione e sulle VDE, considerando questi due problemi quelli che maggiormente andranno ad incidere sul reattore di nuova generazione ITER. In particolare individua alcuni limiti operativi imposti da elevati valori di densità del plasma e dai valori della pressione del plasma.

Per far questo analizza i due fenomeni nei reattori TOKAMAK del JET, TFTR (Tokamak Fusion Test Reactor, Princeton Plasma Physics Laboratory, USA), e JT-60U (Japan Atomic Energy Research Institute, Naka, Japan).

I limiti sui valori della pressione del plasma sono espressi come limiti sul fattore β che misura il bilanciamento delle pressioni a cui è soggetto il plasma. Esso è il rapporto fra la pressione all'interno del plasma e quella del campo magnetico. Le disruzioni ad alto β , β -Limite, sono caratterizzate da un aumento della pressione del plasma che ingenera delle instabilità MHD. Maggiori dettagli teorici sul β si trovano in [15], mentre i risultati sperimentali sono discussi in [16].

Al JET le condizioni per una disruzione β -Limite sono particolarmente rare perché nelle normali condizioni operative della macchina le pressioni non raggiungono il valore limite.

In [17] è riportato lo stato della conoscenza sulla stabilità Magneto Idrodinamica dei plasmi nei TOKAMAK, sulle condizioni di soglia per l'inizio delle instabilità MHD, e sui relativi limiti operativi imposti. Vengono inoltre descritte le conseguenze delle disruzioni, e gli effetti ad esse collegati. L'analisi è volta a studiare come questi problemi possano essere risolti nei reattori di prossima generazione, con particolare riguardo a ITER.

In letteratura sono stati presentati altri tipi di distruzioni, meno frequenti come le instabilità associate agli errori di campo [18] [19] e le disruzioni causate da frammenti solidi presenti nel plasma [20].

Una classificazione di disruzioni è stata presentata in [21], dove si analizzano le disruzioni del TOKAMAK ASDEX UPGRADE (Max-Planck Institut für Plasmaphysik, Garching, Germany). In questo articolo, gli autori hanno visionato gli andamenti dei segnali diagnostici per un elevato numero di disruzioni allo scopo di identificare le cause tecniche, i precursori, e quali meccanismi fisici possono portare ad una disruzione. Il risultato più significativo di questo studio, come sottolineano gli stessi autori, è che la maggior parte delle disruzioni può essere attribuita a cause tecniche esterne ed è quindi 'evitabile'.

Anche se questi studi costituiscono un valido contributo alla comprensione delle disruzioni, essi non forniscono le basi teoriche sufficienti per lo sviluppo di un modello matematico che tenga conto dei complessi fenomeni alla base dei diversi tipi di disruzione. Al momento, in quest'ambito non sono apparsi contributi significativi. Qualche risultato preliminare è stato presentato nei proceeding di recenti conferenze internazionali.

In [22] gli autori addestrano una rete neurale di tipo Multi Layer Perceptron a classificare quattro tipi di disruzione utilizzando i segnali diagnostici di esperimenti condotti negli ultimi anni al JET. I risultati ottenuti dimostrano come le reti neurali siano uno strumento valido per la classificazione automatica di questo fenomeno, a condizione che lo spazio dei parametri che identificano lo stato del plasma, sia sufficientemente definito, e che gli spazi operativi della macchina siano ben descritti dal database utilizzato per definire i parametri del classificatore.

In [23], gli autori propongono di utilizzare come classificatori le Support Vector Machines con le reti Multi Layer Perceptron a Learning Vector Quantization, ma al momento non sono ancora disponibili i risultati.

2.2 Stato dell'arte sulla predizione di disruzioni

Come evidenziato nel paragrafo precedente, i limiti teorici conosciuti non sono sufficienti per sviluppare un modello predittivo.

In tempi recenti si è cercato di superare questo limite, utilizzando tecniche alternative, molte delle quali basate su un approccio neurale.

I lavori presentati in questo campo possono essere divisi in due sezioni:

- ✓ Approcci orientati a predire l'andamento di quelli che sono considerati i precursori di disruzione,
- ✓ Approcci orientati a predire la prossimità oppure la probabilità di disruzione.

2.2.1 Predizione di precursori della predizione

I lavori presentati in questo ambito utilizzano le reti neurali artificiali per predire l'andamento di una o più grandezze caratteristiche del plasma. Questi valori permettono di individuare alcune instabilità dei plasmi che potrebbero portare a disruzione.

In [24] il valore di β_T (valore di β riferito al solo campo toroidale), che è un indice della stabilità del confinamento del plasma, viene stimato da una rete neurale artificiale, sulla base di alcune misure magnetiche nel DIII-D TOKAMAK (San Diego, USA); il valore così stimato viene utilizzato in una seconda fase per identificare il confine fra configurazioni di plasma stabili e configurazioni instabili.

In [25] gli autori addestrano due reti Multi Layer Perceptron a predire le misure delle bobine di Mirnov nel TOKAMAK TEXT (University of Texas, Austin, USA). Da queste misure è possibile identificare i modi del plasma con $m=2$, che sono stati riconosciuti come precursori di disruzione. Il primo Multi Layer Perceptron viene addestrato a predire le misure delle bobine di Mirnov un passo in avanti, cioè la misura al tempo t

viene predetta utilizzando le misure ai tempi: $t-\tau$, $t-2\tau, \dots$, $t-N\tau$, dove τ è il tempo di campionamento dei sistemi diagnostici.

Successivamente le reti addestrate lavorano in maniera autonoma (cioè l'uscita della rete al tempo t è riportata sull'ingresso per il calcolo dell'uscita in $t+\tau$); ciò consente di ottenere una predizione al tempo $t+k\tau$.

Una seconda rete Multi Layer Perceptron è invece addestrata per calcolare le misure delle bobine di Mirnov direttamente al tempo $t+k\tau$, utilizzando le misure ai tempi $t-\tau$, $t-2\tau, \dots$, $t-N\tau$.

Un approccio simile è stato sviluppato in [26] utilizzando anche le misure di raggi X soft. Utilizzando questo tipo di misure le disruzioni vengono predette in anticipo di 3 passi, rispetto alla migliore rete neurale addestrata con le sole misure delle bobine di Mirnov.

Sulla base di questi lavori, in [27] gli autori usano un vettore di ingressi alla rete simile a quello precedentemente descritto, ma i segnali diagnostici utilizzati provengono da più di un sistema diagnostico. Vengono infatti utilizzati quattro segnali provenienti dalle bobine di Mirnov, un segnale di raggi X soft, e un segnale di H_α .

La rete neurale è in grado di predire K passi in avanti tutti i segnali che le vengono forniti in ingresso. I risultati presentati sono migliori rispetto ai casi in cui viene usato un solo tipo di misura; il segnale predetto tende a degradarsi intorno a $K=400$.

Malgrado i risultati molto promettenti di tutti questi metodi, l'approccio utilizzato presenta un importante svantaggio: al momento sono stati individuati i precursori di solo un numero limitato di disruzioni, per cui tutti questi approcci possono essere usati solo in condizioni particolari, e non in tutte le condizioni operative della macchina.

2.2.2 Predizione di disruzioni

Nei lavori presentati nel paragrafo precedente l'obiettivo era predire una grandezza caratteristica del plasma al tempo $t+k\tau$, noto il valore nell'istante t .

Il secondo approccio alla predizione utilizza come uscita della rete un segnale artificiale non misurabile, in grado di fornire l'informazione sull'approssimarsi di un fenomeno disruttivo, o attraverso una probabilità di un evento disruttivo, o sul tempo alla disruzione, o fornisce un semplice indicatore.

Gli articoli presenti in letteratura sono numerosi [28-38] e riguardano approcci sviluppati utilizzando i dati raccolti in diversi reattori. Anche se al momento nessuno di questi approcci ha ancora portato all'implementazione di un sistema da utilizzare durante il normale funzionamento delle macchine, i risultati più recenti sono molto promettenti. Di seguito verranno brevemente descritti e confrontati i più recenti risultati.

In [33] un predittore neurale è stato sviluppato per il TOKAMAK ASDEX Upgrade.

La rete neurale del tipo Multi Layer Perceptron, addestrata con 8 parametri del plasma e le relative derivate nel tempo, ha come target la predizione del tempo alla disruzione almeno 50 ms prima che la disruzione avvenga.

Il predittore è stato implementato on-line e aziona un sistema di mitigazione (injection killer pellet) in grado di ridurre gli sforzi meccanici e i carichi termici sulla macchina durante una disruzione.

E' importante notare che malgrado i buoni risultati ottenuti, gli autori sottolineano il deterioramento delle performance della rete installata on-line. Ciò è dovuto allo scostamento fra i segnali rilevati in real-time e quelli utilizzati per l'addestramento (presenti nel database di ASDEX-U). Inoltre, è stato osservato che nuovi esperimenti che appartengono ad uno spazio operativo della macchina molto diverso da quello rappresentato dal Training Set, non vengono predetti in maniera corretta.

In [34] viene presentato un concetto nuovo, il 'livello di stabilità', utile per predire gli eventi disruttivi. Il livello di stabilità viene calcolato utilizzando 9 parametri del plasma

come ingresso ad una rete neurale. Il sistema neurale segnala il rischio di disruzione quando l'uscita della rete che rappresenta il valore predetto del livello di stabilità è minore di una data soglia. Le disruzioni considerate in questo lavoro appartengono al database di JT60-U e sono causate da: Densità Limite, presenza nel plasma a bassa densità di Modi Bloccati, basso valore di β , alto valore di induttanza interna del plasma durante la fase di ramp-down della corrente di plasma. La rete neurale è stata addestrata utilizzando un Training Set composto da 12 impulsi disrotti e 6 buoni.

In [35] gli autori presentano una rete neurale addestrata con 9 segnali diagnostici relativi a due anni di esperimenti al JET, per valutare il rischio di disruzione almeno 100 ms prima che questa avvenga. E' importante sottolineare che non si ha una considerevole degradazione delle performance se il rischio di disruzione viene predetto 200 ms prima dell'evento.

Attraverso un'analisi di salienza è stata inoltre confermata la bontà dei 9 segnali selezionati.

3. LE RETI NEURALI ARTIFICIALI

La tecnologia delle reti neurali artificiali costituisce un approccio all'elaborazione dell'informazione differente ed in alcuni casi complementare a quello dell'intelligenza artificiale classica.

Il nome deriva dall'iniziale tentativo compiuto dagli informatici di riprodurre artificialmente i processi che si svolgono nelle reti di neuroni del cervello.

I neuroni, cioè le cellule nervose, sono costituiti da un corpo cellulare, l'*assone*, tramite il quale ogni cellula trasmette il proprio segnale a tutte le altre cellule ad essa connesse, e da alcuni *dendriti*, che ricevono i segnali dalle cellule ai quali sono connessi.

La connessione avviene attraverso un processo elettrochimico in un'intercapedine situata tra *assone* e *dendrite*; questa intercapedine, detta *sinapsi*, si modifica nel tempo determinando una variazione nella forza con cui il segnale si trasmette tra una cellula e l'altra.

A scopo esemplificativo, mutuando alcuni termini dall'informatica, diremo che il cervello riceve un ingresso, lo elabora e produce un'uscita. Gli ingressi sono i segnali provenienti dagli organi sensoriali, mentre le uscite sono gli stimoli che comandano l'attivazione di muscoli, corde vocali, ecc..

Le reti neurali artificiali sono strutturate in modo abbastanza simile al cervello: le unità di ingresso corrispondono agli organi sensoriali di un essere vivente; le unità di uscita sono gli stimoli agli attuatori; le connessioni tra le varie unità sono i corrispettivi delle sinapsi. Ad ogni connessione è associato un 'peso' e l'informazione risiede nell'insieme dei pesi.

Nelle reti neurali artificiali, così come nel cervello, l'elaborazione delle informazioni avviene in modo parallelo, cioè l'ingresso viene distribuito su molte unità elementari (neuroni) che concorrono contemporaneamente alla produzione dell'uscita.

La presenza di molte unità di processamento parallele fa sì che l'eventuale perdita di un'unità abbia, nel caso di architetture con molti neuroni, conseguenze non irreparabili.

Inoltre, la modalità di elaborazione in parallelo consente di ottenere tempi di calcolo molto ridotti e rende le reti robuste in presenza di dati rumorosi.

Una rete neurale deve però possedere anche altre proprietà caratteristiche del cervello umano, ad esempio la *plasmabilità* che permette alle sinapsi di modificarsi nel tempo interagendo con segnali provenienti dal mondo esterno.

Questa caratteristica è alla base del processo di apprendimento: la memorizzazione di un'informazione avviene regolando i pesi delle sinapsi, attraverso il rafforzamento o l'indebolimento delle connessioni senza bisogno di un'unità centrale (regola di Hebb) [39]. Il processo neurologico dell'apprendimento avviene allora, non per variazione della relazione ingresso/uscita, ma perché cambia l'intensità della connessione tra neuroni.

L'efficacia con cui un neurone eccita o inibisce un altro neurone non è costante, può crescere o decrescere nel tempo, e dipende sistematicamente dall'esperienza. L'intensità della connessione tra neuroni è determinata quindi esclusivamente dalle informazioni disponibili a livello locale tra le sinapsi. È stato pensato allora di elaborare un algoritmo in grado di modificare l'intensità delle connessioni tra i neuroni di una rete neurale artificiale in relazione agli ingressi che le vengono presentati: i pesi delle connessioni vengono così alterati dall'esperienza e la rete può *imparare*.

Altre caratteristiche della struttura cerebrale umana, che le reti neurali artificiali tentano di riprodurre, sono la *capacità di realizzare associazioni* e di *generalizzare*: la prima consente, una volta concluso il processo di apprendimento, di associare delle forme in uscita a particolari forme in ingresso, la seconda è invece quella capacità che permette alla rete di riconoscere forme note e memorizzate a partire da ingressi incompleti o parzialmente differenti.

I metodi di apprendimento neurale si dividono in due classi: metodo supervisionato e non-supervisionato. Quello maggiormente utilizzato è quello supervisionato in cui si

presentano ripetutamente alla rete degli esempi per modellare la relazione ingresso/uscita e si aggiustano i coefficienti del modello nella direzione che minimizza l'errore tra il dato e l'uscita del modello [39].

Nei casi di apprendimento non-supervisionato la rete scopre da sola regolarità negli stimoli, formando delle rappresentazioni interne dell'insieme degli ingressi sotto forma di clusterizzazione. Così accade nelle reti che sviluppano feature maps [40].

3.1 Multi Layer Perceptron

Il Multy Layer Perceptron (MLP) è una particolare struttura di rete neurale artificiale costituita da più strati di neuroni, in cui ogni neurone è connesso con i neuroni degli strati adiacenti Figura 3.1 [41] [42].

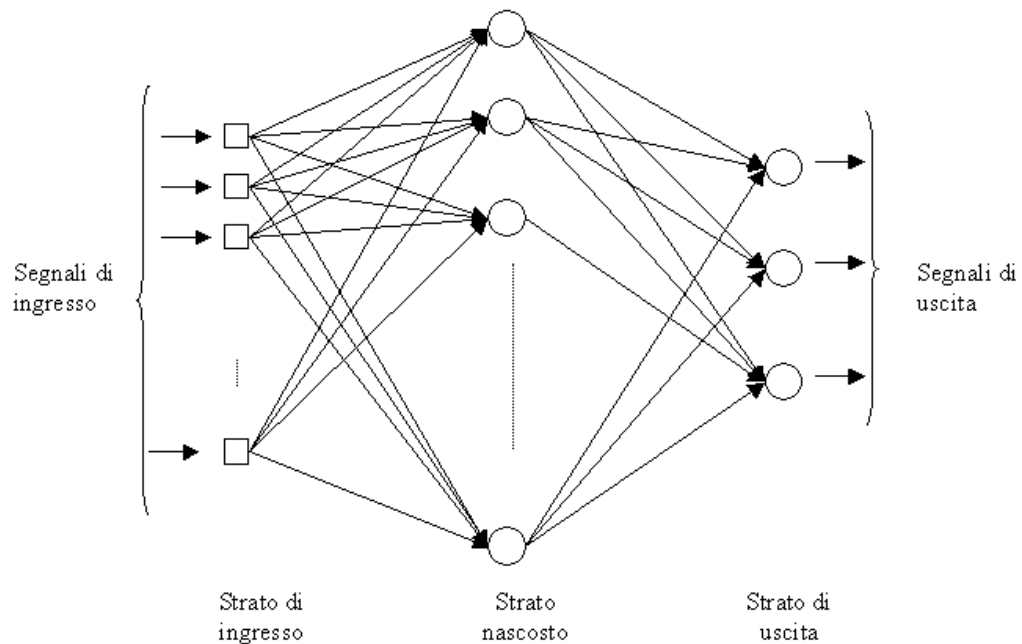


Figura 3.1: Architettura di una rete Multi Layer Perceptron

Matematicamente una rete MLP realizza un combinazione non-lineare delle componenti del vettore degli ingressi.

$$y_k(\mathbf{x}) = f\left(\sum_{i=1}^m w_{ki} g\left(\sum_{j=1}^n w_{ij} x_j + \theta_i\right) + \theta_k\right) = f(\text{net}_k) \quad (3.1)$$

dove y_k rappresenta il valore del k -esimo neurone dello strato di uscita, m è il numero dei neuroni nello strato nascosto, n è il numero dei neuroni nello strato di ingresso, x_j è la j -esima componente del vettore di ingresso; w_{ij} è il peso della connessione fra il neurone i e il neurone j , θ_i e θ_k rappresentano i valori dei bias, e f e g sono le funzioni di attivazione.

Le principali funzioni di attivazione per questo tipo di reti sono:

Logsigmoideale $y = \frac{1}{1 + e^{-ax}}$;

Tangente iperbolica $y = \frac{1 - e^{-ax}}{1 + e^{-ax}}$;

Lineare $y = ax$

3.1.1 Error back propagation: algoritmo di apprendimento

L'addestramento di una rete neurale MLP consiste nel risolvere un problema di ottimizzazione il cui scopo è determinare un insieme ottimo di pesi, cioè tale da minimizzare l'errore commesso in uscita dalla rete.

Gli algoritmi di addestramento maggiormente utilizzati si fondano sulla metodologia Error Back Propagation (EBP).

L'errore tra l'uscita voluta e l'uscita reale della rete per un particolare stato di ingresso viene propagato all'indietro attraverso i pesi degli strati nascosti fino allo strato di ingresso. L'errore è minimizzato mediante la metodologia di Discesa Rapida del Gradiente. Dopo aver effettuato un'operazione di inizializzazione casuale dei pesi, le N coppie ingresso/uscita, appartenenti ad un prefissato insieme di dati $D = \{\mathbf{x}^{(p)}, \mathbf{d}^{(p)}\} \quad p = 1, \dots, N$ vengono iterativamente presentate alla rete MLP fintantoché, attraverso opportune operazioni di modifica dei pesi, non si raggiunge un minimo di una funzione d'errore predefinita, funzione che esprime una misura della distanza tra le uscite desiderate e le corrispondenti uscite che il modello MLP calcola.

Definiamo la funzione d'errore come l'errore quadratico medio:

$$E = \frac{1}{K \cdot N} \cdot \sum_{p=1}^N \sum_{k=1}^K (d_k^{(p)} - y_k^{(p)})^2 \quad (3.2)$$

dove $y_k^{(p)}$ è l'uscita prodotta dalla rete MLP nel k -esimo neurone della rete corrispondente all'ingresso $\mathbf{x}^{(p)}$, $d_k^{(p)}$ la corrispondente uscita desiderata e K il numero di neuroni nello strato di uscita.

L'algoritmo di discesa del gradiente suggerisce di modificare ogni peso w_{ij} di una quantità Δw_{ij} proporzionale al gradiente dell'errore:

$$\Delta w_{ij} = \alpha \frac{\partial E}{\partial w_{ij}} \quad (3.3)$$

Per il calcolo della derivata si utilizza la regola di derivazione a catena:

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial y_i} \cdot \frac{\partial y_i}{\partial net_i} \cdot \frac{\partial net_i}{\partial w_{ij}}$$

dove

$$\begin{aligned} \frac{\partial net_i}{\partial w_{ij}} &= x_j; \quad \frac{\partial y_i}{\partial net_i} = f'(net_i) \\ \frac{\partial E}{\partial y_i} &= \frac{\partial E}{\partial y_k} \cdot \frac{\partial y_k}{\partial y_i} = \frac{\partial E}{\partial y_k} \cdot \frac{\partial y_k}{\partial net_k} \cdot \frac{\partial net_k}{\partial y_i} \end{aligned} \quad (3.4)$$

Essendo

$$\frac{\partial net_k}{\partial y_i} = w_{ki}; \quad \frac{\partial y_k}{\partial net_k} = f'(net_k); \quad \frac{\partial E}{\partial y_k} = e_k$$

si ha:

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial y_k} \cdot \frac{\partial y_k}{\partial y_i} \cdot \frac{\partial y_i}{\partial net_i} \cdot \frac{\partial net_i}{\partial w_{ij}} = -e_k \cdot f'(net_k) \cdot w_{ki} \cdot f'(net_i) \cdot x_j \quad (3.5)$$

da cui

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} = -\eta \cdot e_k \cdot f'(net_k) \cdot w_{ki} \cdot f'(net_i) \cdot x_j \quad (3.6)$$

dove $\eta \in]0,1]$ è il tasso di apprendimento ed in genere è funzione del gradiente.

Scritto in termini vettoriali:

$$\Delta \mathbf{w} = -\eta \cdot \mathbf{g} \quad (3.7)$$

dove \mathbf{g} rappresenta il gradiente alla generica iterazione.

L'algoritmo base appena descritto è eccessivamente lento nel convergere in una rete multistrato e sono state proposte numerose modifiche per renderlo più veloce. Altre variazioni hanno lo scopo di evitare i minimi locali o migliorare la capacità di generalizzazione.

In particolare, la discesa del gradiente è una delle più semplici tecniche di ottimizzazione ma non è tra le più potenti. Prestazioni migliori possono essere ottenute con il metodo di Newton [43] utilizzando la derivata seconda.

$$\Delta \mathbf{w} = -\mathbf{H}^{-1} \cdot \mathbf{g} \quad (3.8)$$

dove \mathbf{H} è la matrice Hessiana della funzione d'errore rispetto ai pesi della rete.

L'algoritmo di Levenberg-Marquardt [43] [44], invece, implementa la variazione di Levenberg-Marquardt al metodo di Newton per modificare i pesi della rete MLP.

La matrice Hessiana è approssimata con:

$$\mathbf{H} \cong 2 \cdot \mathbf{J}^T \cdot \mathbf{J} \quad (3.9)$$

ed inoltre il gradiente viene calcolato con:

$$\mathbf{g} = \mathbf{J}^T \cdot \mathbf{e} \quad (3.10)$$

dove \mathbf{J} è la matrice Jacobiana dell'errore quadratico medio calcolata rispetto ai pesi, mentre \mathbf{e} è il vettore degli errori della rete. Il metodo di quasi-Newton per l'aggiornamento dei pesi può, quindi essere scritto:

$$\Delta \mathbf{w} = -(\mathbf{J}^T \cdot \mathbf{J} + \mu \cdot \mathbf{I})^{-1} \cdot \mathbf{g} \quad (3.11)$$

3.1.2 La generalizzazione con una rete MLP

Negli algoritmi di apprendimento, come quelli presentati, è particolarmente rilevante il ruolo assunto dalla regola utilizzata per far terminare l'apprendimento. Il metodo più classico è quello di porre fine al processo di apprendimento quando il valore dell'errore è inferiore ad una certa soglia prefissata.

Ad una scelta procedurale di questo tipo, tuttavia, può accompagnarsi un fenomeno sfavorevole denominato iper-apprendimento, o 'over-fitting', che consiste nella possibilità che l'algoritmo di apprendimento individui relazioni funzionali tra i vettori di ingresso \mathbf{x} ed i vettori di uscita \mathbf{y} in realtà inesistenti.

Allo scopo di evitare il manifestarsi di inconvenienti di questo tipo, alcuni autori suggeriscono di utilizzare un criterio di Stop-Learning basato sulla Cross-Validation [45].

In un approccio così definito, l'insieme di dati iniziale, contenente le coppie ingresso/uscita, viene suddiviso in due sottoinsiemi ad intersezione vuota, il Training Set ed il Validation Set e, successivamente, l'algoritmo di apprendimento viene applicato iterativamente al Training Set, finché non si è raggiunto un minimo della funzione di costo calcolata sul Validation Set.

3.1.3 Classificazione con una rete MLP

Il problema di classificazione consiste nell'associare al generico vettore di ingresso $\mathbf{x}^{(p)}$ una specifica classe di appartenenza C_k .

Consideriamo una rete MLP con n ingressi, K neuroni in uscita, uno strato nascosto con m neuroni. Il Training Set è composto da $D = \{\mathbf{x}^{(p)}, \mathbf{d}^{(p)}\}$ $p = 1, \dots, N$, se $y_k^{(p)}$ rappresenta allora la k -esima uscita prodotta dalla rete in risposta al prototipo $\mathbf{x}^{(p)}$:

$$y_k^{(p)} = F_k(\mathbf{x}^{(p)}), \quad k = 1, 2, \dots, K. \quad (3.12)$$




Figura 3.2: Diagramma a blocchi di un classificatore MLP

Allora possiamo definire il vettore delle uscite della rete $\mathbf{y}^{(p)}$ come:

$$\begin{aligned} \mathbf{y}^{(p)} &= [y_1^{(p)}, y_2^{(p)}, \dots, y_K^{(p)}]^T \\ &= [F_1(\mathbf{x}^{(p)}), F_2(\mathbf{x}^{(p)}), \dots, F_K(\mathbf{x}^{(p)})]^T \\ &= \mathbf{F}(\mathbf{x}^{(p)}) \end{aligned} \quad (3.13)$$

$\mathbf{F}(\cdot)$ è un vettore di funzioni tali da minimizzare il funzionale del rischio empirico:

$$R_{emp} = \frac{1}{2N} \sum_{p=1}^N \|\mathbf{d}^{(p)} - \mathbf{F}(\mathbf{x}^{(p)})\|^2 \quad (3.14)$$

dove $\mathbf{d}^{(p)}$ rappresenta l'uscita desiderata per il vettore di ingresso $\mathbf{x}^{(p)}$, $\|\cdot\|$ è la distanza euclidea.

L'essenza del funzionale di rischio empirico è la stessa della funzione d'errore di una rete MLP.

L'uscita di una rete MLP addestrata con l'algoritmo di back-propagation su un set finito di esempi indipendenti ed uniformemente distribuiti è l'approssimazione asintotica della probabilità a posteriori [39].

Questa affermazione è giustificata da:

1. Legge dei grandi numeri: se la dimensione del Training Set N tende ad infinito, il vettore dei pesi \mathbf{w} che minimizza il funzionale di rischio empirico, tende al vettore dei pesi ottimi \mathbf{w}^* .
2. Il vettore dei pesi ottimi \mathbf{w}^* possiede la proprietà che il corrispondente vettore delle uscite della rete MLP, $\mathbf{F}(\mathbf{w}^*, \mathbf{x})$, è un'approssimazione del valore atteso condizionato (expectation conditional) del vettore di uscite desiderato, dato il vettore degli ingressi \mathbf{x} [47].
3. Per un problema di classificazione con K classi, se il vettore degli ingressi \mathbf{x} appartiene alla classe C_k , ponendo il k -esimo elemento del vettore delle uscite uguale a 1, e tutti gli altri elementi del vettore uguali a zero, allora il valore atteso condizionato eguaglia la probabilità a posteriori $P(C_k/\mathbf{x})$, $k=1,2,\dots,K$ [48].

Queste considerazioni sono valide anche nel caso in cui il vettore delle uscite sia un numero binario con $\log_2 K$ bits; questa scelta ha lo svantaggio di rendere più difficoltoso il processo di apprendimento, di contro consente una riduzione della dimensionalità dello spazio delle uscite.

3.1.4 Approssimazione di funzioni mediante MLP

Una rete MLP può approssimare qualsiasi funzione continua, sia lineare che non lineare con l'accuratezza che si desidera.

Per dimostrare questa proprietà del MLP è necessario introdurre il *teorema dell'approssimazione universale* [42]:

Sia I_{m_0} un ipercubo unitario m_0 -dimensionale e $C(I_{m_0})$ lo spazio delle funzioni continue in I_{m_0} . Se $f \in C(I_{m_0})$, x_1, x_2, \dots, x_{m_0} il generico vettore appartenente allo spazio degli ingressi, e $F(x)$ una realizzazione della funzione $f(\cdot)$, cioè tale da soddisfare:

$$\left| F(x_1, \dots, x_{m_0}) - f(x_1, \dots, x_{m_0}) \right| < \varepsilon \quad \forall \varepsilon > 0 \quad (3.15)$$

allora esiste un insieme di costanti reali α_i, b_i e w_{ij} , con $i = 1, \dots, m_1$ e $j = 1, \dots, m_0$ tali che:

$$F(x_1, \dots, x_{m_0}) = \sum_{i=1}^{m_1} \alpha_i \varphi \left(\sum_{j=1}^{m_0} w_{ij} x_j + b_i \right) \quad (3.16)$$

dove $\varphi(\cdot)$ è una funzione continua, non-costante, limitata, monotona crescente.

Il teorema dell'approssimazione universale è applicabile in modo diretto al Multi Layer Perceptron.

Le funzioni di attivazione del MLP soddisfano le proprietà della funzione $\varphi(\cdot)$, cioè sono funzioni continue, non-costanti, limitate, monotone crescenti.

Inoltre la realizzazione della funzione $f(\cdot)$ coincide con l'uscita di una rete MLP, se:

1. la rete MLP ha m_0 neuroni di ingresso, un solo strato nascosto con m_1 neuroni e gli elementi del vettore di ingresso sono x_1, x_2, \dots, x_{m_0} ,
2. w_i, \dots, w_{m_0} sono i pesi dell' i -esimo neurone nascosto, e b_i il bias,
3. L'uscita della rete è una combinazione lineare delle uscite dei neuroni nascosti con $\alpha_1, \alpha_2, \dots, \alpha_{m_1}$ pesi dei neuroni dello strato di uscita.

Partendo da questi considerazioni in [49], Cybenko ha dimostrato che una rete MLP a singolo strato nascosto e con funzione di attivazione sigmoideale, è in grado di approssimare arbitrariamente un qualunque legame funzionale continuo da uno spazio di dimensione finita ad un altro, purché il numero di neuroni sia adeguato.

Il teorema di Cybenko è comunque di tipo non costruttivo, ovvero non fornisce un metodo per ottenere le rete neurale approssimante una funzione data. Neppure viene dato un maggiorante (magari asintotico) per l'errore di approssimazione commesso impiegando un certo numero m di neuroni nello strato nascosto. In letteratura esistono diversi studi in questa direzione; in [50] è riportata una review dei principali risultati anche se gli algoritmi sinora proposti tendono ad eccedere con il numero di neuroni selezionati rendendoli praticamente inutilizzabili.

3.2 Support Vector Machines

Le Support Vector Machine (SVM) nascono intorno agli anni '70 ad opera di Boser, Guyon, Vapnik e Cortes [51] [52] [53] suscitando, da allora, un interesse sempre crescente per lo studio di problemi di classificazione e di regressione non lineare [54] [55]. Come le reti neurali, esse sono in grado di apprendere delle relazioni funzionali sulla base degli esempi, 'learning machine' [56], ma differiscono nel metodo di apprendimento che nel loro caso tende ad ottimizzare la capacità di generalizzazione, minimizzando il rischio statistico di errore.

Le proprietà della macchina addestrata, in particolare la sua capacità di generalizzare, vengono valutate in termini statistici, e questo aspetto influenza il metodo di apprendimento.

3.2.1 Basi teoriche

Un generico problema di classificazione è definito da un insieme di vettori $\mathbf{x} \in \mathfrak{R}^n$, dove \mathfrak{R}^n è uno spazio a valori reali, e da un corrispondente insieme di vettori $\mathbf{d} \in \mathfrak{R}^K$ che rappresentano le classi dei vettori \mathbf{x} , e che sono definiti in uno spazio a valori binari di dimensione K , nel senso che in genere ogni classe è rappresentata mediante una codifica binaria. La variabile \mathbf{x} può essere considerata aleatoria, di conseguenza anche \mathbf{d} sarà una variabile aleatoria, e sarà legata alla \mathbf{x} mediante una probabilità condizionata incognita $P(\mathbf{d} | \mathbf{x})$.

Una learning machine, di cui le SVM rappresentano una tipologia, dovrà dunque implementare un insieme di funzioni $f(\mathbf{x}, \alpha) = \mathbf{d}$ che minimizzino l'errore sull'insieme di esempi utilizzati per addestrare la macchina (Training set) $TS = \{(\mathbf{x}^{(1)}, \mathbf{d}^{(1)}), (\mathbf{x}^{(2)}, \mathbf{d}^{(2)}), \dots, (\mathbf{x}^{(N)}, \mathbf{d}^{(N)})\}$, cioè su quell'insieme di dati di cui si conosce la classificazione, e che si presume siano in grado di rappresentare il problema in esame, condizione questa già presentata nel caso degli MLP.

La capacità di generalizzazione di una learning machine, intesa come la capacità di fornire classificazioni corrette di esempi non appartenenti al Training Set, è misurata mediante una funzione:

$$R(\alpha) = \int L(\mathbf{d}, f(\mathbf{x}, \alpha)) dP(\mathbf{d}, \mathbf{x}) \quad (3.17)$$

dove L è una generica funzione di perdita, $R(\alpha)$ è convenzionalmente chiamato funzionale di rischio strutturale. L'obiettivo di una learning machine è quello di minimizzare il funzionale di rischio strutturale (SRM).

Come abbiamo visto nel Par. 3.1.1 le reti MLP minimizzano il funzionale di rischio empirico (ERM).

Tuttavia il funzionale di rischio empirico non coincide con il funzionale di rischio strutturale. L'SRM rappresenta un limite superiore sul rischio atteso, a differenza dell'ERM che rappresenta, invece, l'errore sui dati di addestramento [54] [55].

Inoltre, sussiste la seguente importante relazione fra il funzionale di rischio ed il rischio empirico:

$$R(\alpha) \leq R_{EMP} + \Omega(h) \quad (3.18)$$

Il parametro h è un numero intero non negativo detto dimensione Vapnik-Chervonenkis (VC) ed è una misura della capacità della macchina, intesa come l'abilità della macchina di imparare qualsiasi Training Set senza commettere errori, $\Omega(h)$ è chiamato invece confidenza VC.

Dunque per minimizzare $R(\alpha)$, e avere una elevata capacità di generalizzazione, occorre minimizzare non solo il funzionale di rischio empirico, ma anche la confidenza VC. Le SVM minimizzano il funzionale di rischio strutturale.

Le Support Vector Machines sono infatti delle learning machines che presentano la capacità di modificare la dimensione VC durante la fase di addestramento. In questo modo sono in grado di minimizzare contemporaneamente la dimensione VC e il numero di errori sul Training Set.

Nelle reti MLP, invece, una volta che l'architettura è stata fissata, lo è di conseguenza anche la dimensione VC. In questo modo, se si tiene VC basso, si impone un limite

inferiore al rischio empirico, di contro per diminuire il rischio empirico deve aumentare la dimensione di VC.

3.2.2 Caso lineare

Si consideri dapprima il caso di due classi linearmente separabili, situazione molto semplice per un classificatore.

Etichettiamo i dati di addestramento come $D = \{\mathbf{x}^{(p)}, d^{(p)}\}, p = 1, \dots, N$, $d^{(p)} \in \{-1, 1\}$, $\mathbf{x}^{(p)} \in \mathfrak{R}^n$, per $d^{(p)} = 1$ l'esempio p -esimo appartiene alla classe I, per $d^{(p)} = -1$ alla classe II.

Si supponga di riuscire a separare gli esempi positivi da quelli negativi con un iperpiano, detto *iperpiano separatore*. I punti \mathbf{x} che giacciono su questo iperpiano soddisfano l'equazione:

$$\mathbf{w}^T \mathbf{x} + b = 0 \tag{3.19}$$

dove \mathbf{w} è normale all'iperpiano, mentre $|b|/\|\mathbf{w}\|$ è la distanza dell'iperpiano dall'origine. Siano d_+ e d_- la più piccola distanza dell'iperpiano separatore dal più vicino esempio positivo e negativo rispettivamente.

Si definisce *margin* di un iperpiano separatore la distanza $(d_+) + (d_-)$. Nel caso di insiemi linearmente separabili, l'algoritmo SVM ricerca semplicemente l'iperpiano separatore con il margine più ampio. Il problema può essere formulato nel seguente modo.

Si supponga che tutti i dati del Training Set soddisfano i seguenti vincoli:

$$\mathbf{w}^T \mathbf{x} + b \geq +1 \text{ per } d^{(p)} = +1 \tag{3.20}$$

$$\mathbf{w}^T \mathbf{x} + b \leq -1 \text{ per } d^{(p)} = -1 \tag{3.21}$$

che possono essere scritti in un'unica disequazione:

$$d^{(p)}(\mathbf{w}^T \mathbf{x}^{(p)} + b) \geq 1 \quad \forall p \quad (3.22)$$

Se si considerano i punti per cui la (3.20) è soddisfatta in senso stretto (punti che esistono sempre se si adotta un'opportuna scala per \mathbf{w} e per b), questi punti giaceranno sull'iperpiano H_1 (vedi Figura 3.3) la cui normale è \mathbf{w} e la cui distanza dall'origine è pari a $|-1-b|/\|\mathbf{w}\|$. Analogamente, i punti che soddisfano l'uguaglianza dell'equazione (3.21) si trovano sull'iperpiano H_2 , con stessa normale, ma distanza dall'origine pari a $|+1-b|/\|\mathbf{w}\|$. Pertanto il margine vale semplicemente $2/\|\mathbf{w}\|$. Quindi è possibile individuare la coppia di iperpiani che forniscono il massimo margine semplicemente minimizzando $\|\mathbf{w}^2\|$, soggetto al vincolo (3.22).

In Figura 3.3 è rappresentata la soluzione per un caso bidimensionale.

Di notevole importanza per le SVM sono i punti per i quali vale l'uguaglianza dell'equazione (3.22), cioè quelli che giacciono su uno dei due iperpiani, e che sono detti *vettori di supporto*.

I vettori di supporto sono gli elementi critici dell'insieme di Training: sono i punti più vicini alla superficie di decisione (cioè quelli su cui viene costruito l'iperpiano). Si noti che se si eliminassero tutti gli altri punti e si ripete l'addestramento, si troverebbe lo stesso iperpiano separatore. In Figura 3.3 i vettori di supporto sono evidenziati in neretto.

In questo caso la soluzione per il problema di ottimizzazione è globale. Questo è un vantaggio considerevole rispetto alle reti MLP dove il minimo globale non è garantito.

Se il Training Set ha dimensioni elevate, il calcolo può essere notevolmente semplificato convertendo il problema nel problema equivalente duale lagrangiano.

Questa metodologia presenta due vantaggi principali:

1. Il vincolo (3.22) verrà sostituito da un vincolo sugli stessi moltiplicatori lagrangiani, con una maggiore facilità di manipolazione;
2. I dati compariranno solo in forma di prodotto scalare fra vettori, il che sarà di particolare aiuto nella generalizzazione al caso non lineare.

In questa formulazione vengono introdotti i moltiplicatori lagrangiani positivi $\alpha^{(p)}$ con $p=1, \dots, N$, uno per ogni disequazione del tipo (3.22).

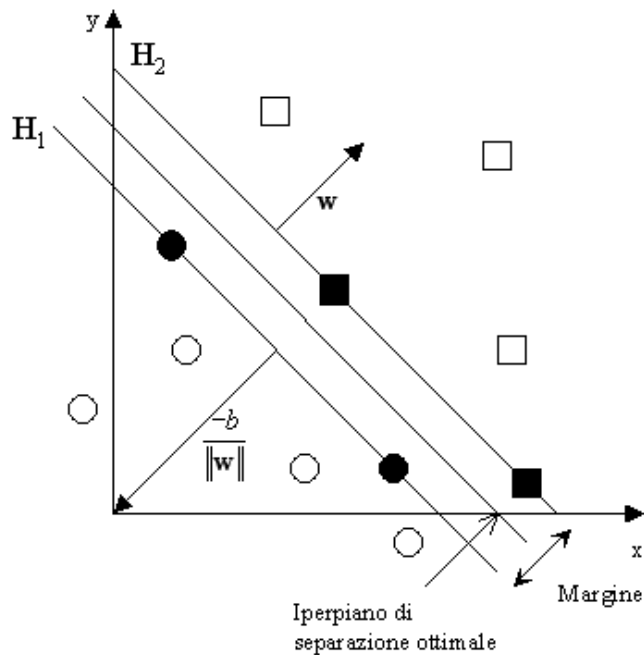


Figura 3.3: Esempio di separazione lineare

Si ottiene la seguente equazione, ottenuta con il rilassamento lagrangiano del vincolo:

$$L_p = \frac{1}{2} \mathbf{w}^T \mathbf{w} - \sum_{p=1}^N \alpha^{(p)} d^{(p)} (\mathbf{w}^T \mathbf{x}^{(p)} + b) + \sum_{p=1}^N \alpha^{(p)} \quad (3.23)$$

Questa formulazione del metodo richiede di minimizzare L_p rispetto a \mathbf{w} e contemporaneamente annullare la derivata di L_p rispetto a tutti gli $\alpha^{(p)}$, con il vincolo di non negatività per tutti i moltiplicatori ($\alpha^{(p)} \geq 0$) (si chiami C1 questo particolare insieme di vincoli). Osserviamo che si tratta di un problema di programmazione quadratica convessa, visto che la funzione obiettivo è essa stessa convessa e che i punti che soddisfano i vincoli formano un insieme convesso. Questo vuol dire che possiamo, in modo equivalente, risolvere il seguente problema duale: massimizzare L_p , soggetto ai vincoli che il gradiente di L_p rispetto a \mathbf{w} e a b si annullino e soggetto alla disuguaglianza $\alpha^{(p)} \geq 0$ (vincoli C2). Questa particolare formulazione è chiamata duale di Wolfe.

Il richiedere che il gradiente si annulli comporta:

$$\mathbf{w}^T \mathbf{w} = \sum_{p=1}^N \alpha^{(p)} d^{(p)} \mathbf{w}^T \mathbf{x}^{(p)} \quad (3.24)$$

$$\sum_{p=1}^N \alpha^{(p)} d^{(p)} = 0 \quad (3.25)$$

Essendo i vincoli nella formulazione duale vincoli di uguaglianza, possono essere sostituiti nell'equazione (3.23) portando alla seguente formulazione:

$$L_d = \sum_{p=1}^N \alpha^{(p)} - \frac{1}{2} \sum_{p=1}^N \sum_{q=1}^N \alpha^{(p)} \alpha^{(q)} d^{(p)} d^{(q)} \mathbf{x}^{(p)T} \mathbf{x}^{(q)} \quad (3.26)$$

soggetto ai vincoli:

$$\sum_{p=1}^N \alpha^{(p)} d^{(p)} = 0 \quad (3.27)$$

$$\alpha^{(p)} \geq 0 \text{ per } p = 1, \dots, N \quad (3.28)$$

Quindi L_p e L_d nascono dalla stessa funzione obiettivo ma con vincoli differenti: la soluzione si ottiene o minimizzando L_p o massimizzando L_d . E' importante sottolineare che esiste un moltiplicatore lagrangiano per ogni vettore del Training Set e tutti quei punti per cui $\alpha^{(p)} > 0$ sono i vettori di supporto, mentre per tutti gli altri punti vale $\alpha^{(p)} = 0$. I vettori di supporto permettono di ottenere una soluzione sparsa al problema, rendendo questo metodo computazionalmente più conveniente.

L'algoritmo descritto in precedenza non produce alcuna soluzione ammissibile se viene applicato a dati non separabili, in quanto non è possibile trovare un iperpiano di separazione tra le due classi. Ciò è evidenziato dal fatto che, la funzione obiettivo, nella sua formulazione lagrangiana duale, diventa arbitrariamente grande.

Si rende necessario rilassare i vincoli (3.20) e (3.21) in caso di dati non separabili, introducendo un costo aggiuntivo nella funzione obiettivo del primale. Per far questo si aggiungono nelle equazioni vincolari delle variabili slack positive $\xi^{(p)}$, $i = 1, \dots, N$ ottenendo:

$$\mathbf{w}^T \mathbf{x} + b \geq +1 - \xi^{(p)} \text{ per } d^{(p)} = +1 \quad (3.29)$$

$$\mathbf{w}^T \mathbf{x} + b \leq -1 + \xi^{(p)} \text{ per } d^{(p)} = -1 \quad (3.30)$$

In pratica $\sum_p \xi^{(p)}$ è un limite superiore al numero degli errori sul Training Set.

Assegnare un costo aggiuntivo agli errori vuol dire modificare la funzione obiettivo che deve essere minimizzata da $\|\mathbf{w}\|^2/2$ a $\|\mathbf{w}\|^2/2 + C(\sum_p \xi^{(p)})^k$, dove C è un parametro

scelto dal progettista, intendendo che ad un C maggiore corrisponde assegnare una maggiore penalità all'errore, per cui diminuisce l'errore sul Training Set, ma diminuisce la capacità di generalizzazione delle SVM.

Un esempio di caso non separabile è riportato in Figura 3.4.




Figura 3.4: Esempio di caso non separabile linearmente

Sia nel caso separabile che in quello non separabile la funzione di decisione è la stessa, data la soluzione ottima α^* e b^*

$$f(\mathbf{x}) = \sum_{i=\text{vettori di supporto}} \alpha_i^* d_i \mathbf{x}_i^T \mathbf{x} + b^* \quad (3.31)$$

Il generico vettore \mathbf{x} viene classificato secondo il seguente criterio:

$$\mathbf{x} \in \begin{cases} \text{Classe I se } f(x) > 0 \\ \text{Classe II se } f(x) < 0 \end{cases} \quad (3.32)$$

3.2.3 Support Vector Machines non lineari

Nel caso lineare la funzione $f(\mathbf{x})$ è una funzione che attribuisce il vettore \mathbf{x} ad una classe a seconda del semispazio, definito dall'iperpiano separatore ottimale, in cui tale vettore si trova.

Esistono, però, molte situazioni, come quella presa in esame in questo lavoro di tesi, in cui la funzione di decisione non è una funzione lineare dei dati. In queste situazioni può accadere però (teorema di Cover sulla separabilità dei pattern) che problemi non separabili nello spazio degli ingressi \mathcal{R}^n lo siano se proiettati in un generico spazio \mathcal{H} a maggior dimensionalità [56].

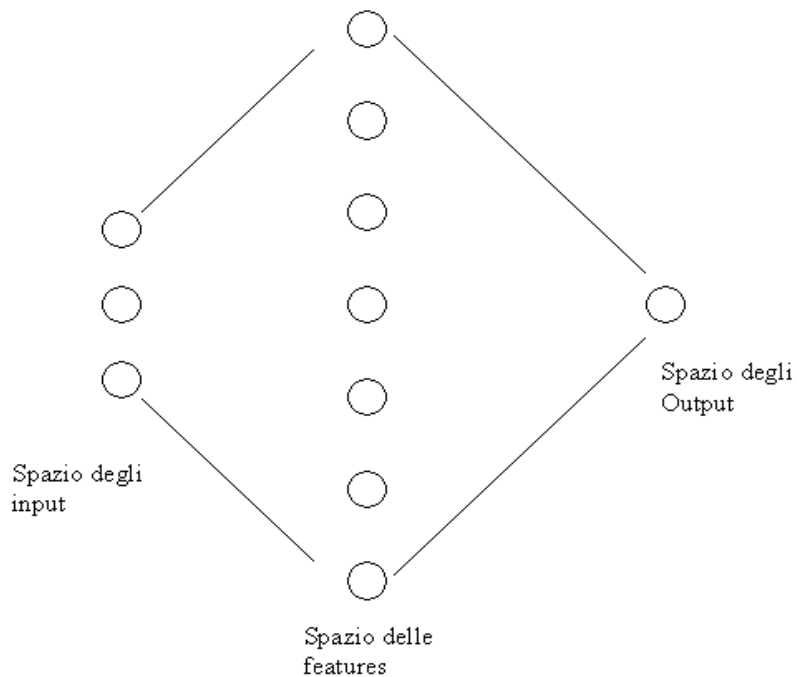


Figura 3.5: Mapping dello spazio degli ingressi in uno spazio delle features ad alta dimensionalità

Questo teorema suggerisce, quindi, di proiettare i dati di ingresso in uno spazio più ampio dove risultano linearmente separabili, e poi cercare in questo spazio \mathcal{H} (spazio delle features) l'iperpiano separatore ottimale.

Utilizzando una funzione di vettori non lineari $\boldsymbol{\varphi}(\mathbf{x}) = (\varphi_1(\mathbf{x}), \dots, \varphi_l(\mathbf{x}))^T$ ($l \gg n$) per mappare un vettore di ingresso n -dimensionale in uno spazio delle features l -dimensionale, la funzione di decisione vista prima diventa:

$$f(\mathbf{x}) = \sum_{i=\text{vettori di supporto}} \alpha_i^* d_i \varphi(\mathbf{x}_i)^T \varphi(\mathbf{x}) + b^* \quad (3.33)$$

Lavorare in uno spazio ad alta dimensionalità come quello delle features permette di lavorare con funzioni complesse, ma questo comporta alcuni svantaggi. Possono insorgere dei problemi computazionali a causa delle dimensioni dei vettori ed inoltre, proprio per l'alta dimensionalità, diventa più delicato il problema dell'over-fitting. Il problema dell'over-fitting è in realtà limitato dall'uso dei vettori di supporto, mentre il problema computazionale è attenuato con una scelta opportuna delle funzioni, 'Kernel'. Le funzioni Kernel, $K(\mathbf{x}, \mathbf{z})$ sono utilizzate per proiettare i vettori dello spazio degli ingressi nello spazio delle features. Tali funzioni godono della seguente proprietà:

$$K(\mathbf{x}, \mathbf{z}) = \varphi(\mathbf{x})^T \cdot \varphi(\mathbf{z}) \quad (3.34)$$

Osservando che i dati nell'algoritmo di addestramento appaiono nell'unica forma di prodotto scalare l'apprendimento nello spazio delle features non richiede di valutare esplicitamente la funzione φ , grazie alla proprietà (3.34).

Utilizzando le funzioni Kernel la funzione di decisione sarà:

$$f(\mathbf{x}) = \sum_{i=\text{vettori di supporto}} \alpha_i^* d_i K(\mathbf{x}_i, \mathbf{x}) + b^* \quad (3.35)$$

ed i dati di cui non è nota la classe di appartenenza sono classificati come è stato descritto in precedenza.

Alcuni esempi di Kernel sono:

Tipo di Kernel	Espressione
Polinomiale	$K(\mathbf{x}, \mathbf{z}) = (\mathbf{x} \cdot \mathbf{z} + 1)^p$
Gaussiano Radial basis Function	$K(\mathbf{x}, \mathbf{z}) = e^{-\ \mathbf{x}-\mathbf{z}\ ^2/2\sigma^2}$
Sigmoidale a doppio strato	$K(\mathbf{x}, \mathbf{z}) = \tanh(b\mathbf{x} \cdot \mathbf{z} - c)$

Tabella 3-1: Alcuni esempi di funzioni di Kernel

3.2.4 Progettazione di una SVM

La progettazione di un classificatore SVM consiste nello scegliere la funzione di Kernel, e il settaggio del parametro C . Il parametro C viene chiamato penalità d'errore, 'error penalty', perché rappresenta il legame tra il margine massimo e l'errore di classificazione in fase di addestramento. Infatti un alto valore di C forza l'addestramento dell'SVM a evitare tutti gli errori, chiaramente, questo implica che durante l'ottimizzazione dei parametri gli iperpiani separatori sono scelti in modo da classificare correttamente tutti i punti del Training Set, restituendo degli iperpiani separatori molto irregolari. Ciò, probabilmente, causerà un deperimento delle capacità di generalizzazione, riducendo le prestazioni quando si classificano esempi del Test Set.

Anche la selezione delle funzione Kernel, ha una notevole influenza sulle superfici di decisione. Normalmente si preferiscono le Radial Basis Functions alle funzioni

polinomiali, perché le prime sono meno sensibili agli esempi anomali presenti nel Training Set, e non richiedono che gli esempi abbiano uguale varianza. Tuttavia, in qualche caso i Kernel polinomiali hanno presentato eccellenti prestazioni come classificatori.

Oltre a scegliere il tipo di Kernel, è necessario, in fase di progetto, stabilire i parametri del Kernel che è stato scelto. Ad esempio, quando viene scelto una funzione di Kernel polinomiale, il parametro da settare è il grado del polinomio, p in Tabella 3-1, mentre, nel caso delle Radial Basis Functions, il parametro è la varianza σ in Tabella 3-1. Un valore di σ elevato permette di avere delle superfici di decisione più regolari.

Dopo quanto detto, è evidente che la scelta della funzione del Kernel dipende fortemente dal problema in esame. Purtroppo non esistono però delle linee guida che possano essere d'aiuto in questa scelta. Normalmente, infatti, le funzioni Kernel vengono scelte, in mancanza di informazioni sul fenomeno che si sta analizzando che possano aiutare questa scelta, con una tecnica di 'trial and error' oppure con un metodo di 'cross-validation'.

La selezione della funzione Kernel presenta difficoltà simili a quelle della selezione dell'architettura di rete di una rete MLP.

3.3 Self Organizing Maps

Le Self Organizing Maps (SOM), note anche come reti di Khonen dal nome del loro inventore [57] [58] [59], costituiscono il modello più utilizzato di reti non supervisionate.

Nelle reti non supervisionate non è disponibile alcun feedback dall'ambiente esterno che permette di verificare se l'uscita della rete è corretta o come essa possa essere modificata. La rete, durante la fase di addestramento, deve scoprire da sola caratteristiche, regolarità statistiche, correlazioni e categorie presenti nei dati di ingresso

e codificarli nell'uscita. Le singole unità e le connessioni devono così presentare un certo grado di auto-organizzazione.

Le uscite di una rete SOM possono essere interpretate in vari modi:

Clustering: un set di uscite di valore binario, di cui uno solo alto, può indicare a quale categoria appartiene un dato pattern di ingresso. Le diverse categorie sono state trovate dalla rete sulla base delle correlazioni presenti nei dati di ingresso. Ciascun cluster formato da ingressi simili può essere classificato come l'uscita di una singola classe.

Prototyping: la rete può evidenziare la presenza di diverse categorie come nel caso precedente, ma restituire come uscita un prototipo o un esempio appartenente a quella categoria. Può svolgere quindi la funzione di memoria associativa, ma la memoria è stata estrapolata direttamente dai pattern di ingresso e non imposta dall'esterno.

Feature Mapping: le SOM, come verrà meglio descritto in seguito, presentano una topologia ordinata, che permette il loro utilizzo per mappare e categorizzare uno spazio ad alta dimensionalità (spazio degli ingressi) in uno a bassa (mappa SOM) riuscendo però a preservare le proprietà topologiche dello spazio iniziale.

È importante notare come l'apprendimento non supervisionato può essere utile anche in quelle situazioni in cui è possibile l'apprendimento supervisionato:

- ✓ Il processo di addestramento di una rete MLP è estremamente lento perché la ricerca del peso migliore per un neurone dipende dai pesi di tutti gli altri neuroni. Questo problema può essere in parte risolto con un sistema ibrido in cui almeno uno strato si addestra da solo.
- ✓ Anche dopo che una rete neurale supervisionata è stata addestrata, può essere necessario un successivo addestramento non supervisionato in modo da adattare la rete ai cambiamenti gradualmente del sistema.

Le reti SOM presentano una semplice topologia costituita da un singolo strato di unità di uscita completamente connesso con le unità di ingresso.

L'uscita è generalmente organizzata in una griglia o mappa mono o bidimensionale. Tale mappa consiste in un numero m di neuroni, ognuno dei quali è rappresentato da un vettore 'prototipo' $\mathbf{w} = [w_1, \dots, w_n]$, di dimensione n pari a quella del vettore di ingresso.

Ogni neurone della rete corrisponde ad un cluster cioè un raggruppamento omogeneo dei dati di ingresso localizzati in quella zona per un qualche criterio di similarità individuato dalla rete. Nella pratica anche più neuroni possono definire un unico cluster.

Ogni neurone di uscita è legato ai neuroni vicini tramite una 'funzione di vicinato' che impone la topologia o la struttura alla mappa. Neuroni vicini corrispondono a ingressi simili. Una mappa SOM è quindi una mappa topografica, cioè è una mappa che preserva le relazioni di vicinato presenti nei dati di ingresso.

3.3.1 Algoritmo di apprendimento

L'apprendimento delle SOM avviene tramite un processo iterativo.

Ogni vettore di ingresso \mathbf{x} è confrontato con tutti i vettori prototipo \mathbf{w} , al fine di individuare la Best-Matching Unit (BMU) cioè quel neurone il cui vettore peso presenta la minima distanza dal vettore di ingresso.

Il BMU è chiamato neurone vincitore e si indica con \mathbf{c} .

$$\mathbf{c} : \mathbf{w}_c = \min \|\mathbf{x} - \mathbf{w}_i\| \quad (3.36)$$

dove \mathbf{w}_i è il generico vettore prototipo.

Si definisce errore di quantizzazione la distanza euclidea fra il vettore di ingresso e il corrispondente BMU.

Il vettore prototipo del neurone vincitore e un certo numero di neuroni circostanti (definite secondo la nozione di bolla) sono modificati secondo la relazione:

$$\Delta \mathbf{w}_i = \eta h_{i,c}(\mathbf{x} - \mathbf{w}_i) \quad (3.37)$$

dove il parametro $\eta \in]0,1]$ è detto velocità di apprendimento e $h_{i,c}$ è la funzione di vicinato, generalmente una gaussiana centrata nel neurone vincitore di raggio variabile durante l'addestramento.

La Figura 3.6 mostra una rappresentazione di una Self Organizing Map durante un processo di addestramento/adattamento. Il cerchio nero indica il neurone vincitore per la rappresentazione del pattern \mathbf{x} .

Il vettore prototipo del neurone vincente, \mathbf{w}_c , è adattato durante la fase di apprendimento al pattern di ingresso, perciò $\mathbf{w}_c(t+1)$ sarà più vicino al vettore di ingresso \mathbf{x} di quanto lo fosse $\mathbf{w}_c(t)$, avendo indicato con t l'indice di iterazione. Tale processo di adattamento, coinvolge anche un numero di neuroni prossimi al vincitore. In Figura 3.6 questo è stato rappresentato mediante una scala di tonalità di grigio.

La variazione della velocità di apprendimento e del raggio della gaussiana consente di dividere il processo di auto-organizzazione della mappa in due fasi. Nella fase iniziale dell'apprendimento, molti neuroni sono coinvolti nell'adattamento. Tali neuroni subiscono variazioni di rilievo (valori dei due parametri elevati), mentre, al termine di questa prima fase, quando ormai ogni neurone si è specializzato nel rispondere a particolari patterns di ingresso, i valori dei parametri assumono valori bassi per rifinire la mappa.

Ad apprendimento ultimato, se all'interno del Training Set erano presenti delle regolarità statistiche, questo avrà guidato una differenziazione spontanea dei neuroni, con la formazione di cluster nella Self Organizing Map.




Figura 3.6: Istantanea della fase di addestramento di una rete SOM

4. LA CLASSIFICAZIONE DELLE DISRUZIONI

Le disruzioni sono un problema endemico e al momento ineliminabile delle operazioni in un reattore TOKAMAK, capaci di porre in serio pericolo l'integrità della macchina e la sua stessa durata in vita.

Poiché la comunità scientifica le considera un notevole ostacolo allo sviluppo della fusione nucleare con macchine TOKAMAK, la loro dinamica è stata ampiamente studiata [9-21] negli ultimi anni. Ciononostante non è stata sviluppata una trattazione globale e completa del problema delle disruzioni, né individuate le leggi fisico-matematiche che sottendono a quell'insieme di eventi osservati durante una disruzione.

I lavori riportati in letteratura, basati principalmente sull'osservazione di database di disruzioni più o meno ampi, hanno comunque messo in luce alcune proprietà e fenomeni che possono essere considerati un punto di partenza per una classificazione delle disruzioni.

Durante una normale campagna sperimentale è importante conoscere la causa di una disruzione, che permette di individuare quali parametri della macchina devono essere reimpostati per evitare il ripetersi dell'evento nell'impulso successivo, che generalmente è molto simile a quello che lo ha preceduto. Affinché però questa classificazione possa essere utile e vantaggiosa deve essere rapida ed univoca, caratteristiche queste, che come abbiamo visto prima, la classificazione manuale non possiede, mentre sono possedute da un classificatore automatico.

Inoltre, conoscere la classe di appartenenza dell'intero database di disruzioni al JET si è rivelato particolarmente utile per successivi studi sulle disruzioni, rendendo patrimonio comune e fruibile da chiunque quello che prima era un sapere di pochi esperti di disruzioni.

La classificazione manuale è stato il primo e fondamentale passo nella progettazione di un classificatore automatico di disruzioni con tecniche neurali supervisionate.

Essa è stata effettuata in collaborazione con alcuni fisici del JET-Team.

Il processo di classificazione manuale è un processo che può essere suddiviso in più fasi:

- ✓ Selezione di un insieme di disruzioni;
- ✓ Selezione dei segnali diagnostici da osservare per individuare la classe di appartenenza;
- ✓ Attribuzione di ogni disruzione ad una classe di appartenenza.

Poiché il JET è una macchina sperimentale, nel database sono presenti gruppi di disruzioni che, pur presentando caratteristiche comuni, non sono attribuibili ad una delle classi di disruzione presenti in letteratura.

La classificazione finale è nata dal confronto fra i risultati di due operatori che hanno lavorato separatamente; è importante sottolineare che non sempre si è raggiunta una soluzione univoca. In questi casi gli operatori hanno ripetuto la classificazione fino a raggiungere l'accordo.

I risultati della classificazione manuale sono stati utilizzati per l'addestramento dei classificatori automatici.

In questo lavoro di tesi, sono state utilizzate due tecniche di classificazione non parametrica; Multi Layer Perceptron e Support Vector Machines; una tecnica di clusterizzazione non parametrica: Self Organizing Maps; e una tecnica di classificazione statistica: k-Nearest-Neighbour.

I metodi parametrici si basano sull'assunzione che sia conosciuta la funzione densità di probabilità, che poi si utilizza per individuare le superfici di separazione tra le classi di appartenenza.

Al contrario, i metodi non-parametrici non fanno nessun assunzione a priori; per questo motivo questo genere di metodi può essere applicato a molti casi reali per i quali

generalmente non è conosciuta la funzione densità di probabilità o quando essa non può essere ricondotta a distribuzioni classiche, come nel caso di densità multi-modali.

L'uso di tecniche di clusterizzazione è giustificato dall'esiguo numero di impulsi classificati manualmente. Infatti queste tecniche si basano su metodi di apprendimento non-supervisionati e non necessitano quindi della conoscenza della classe di appartenenza degli esempi del Training Set.

I termini clusterizzazione e classificazione sono spesso usati come sinonimi, anche se esistono delle differenze significative.

Il clustering è il processo di raggruppamento di ingressi vicini (in termini di distanza euclidea) nello spazio degli ingressi; la classificazione invece è l'assegnazione di etichette ai patterns in ingresso a partire da un criterio fornito dall'esterno. Dal momento che i clusters sono ricavati dalla distribuzione dei dati in ingresso, per uno stesso numero N di patterns può essere individuata più di una suddivisione in cluster, a seconda delle caratteristiche che si decide di fare pesare maggiormente. Per questi motivi, è difficile applicare una tecnica di clusterizzazione direttamente ad un problema di classificazione.

Le tecniche utilizzate sono state confrontate. L'MLP ha presentato le migliori prestazioni.

L'uso di un singolo classificatore non permette, però, di utilizzare tutte le informazioni discriminatorie e complementari che altri classificatori possono aver appreso dal Training Set. Inoltre le solo performance sul Test Set non sono sufficienti a garantire le buone capacità di generalizzazione delle rete MLP selezionata come la migliore, date le dimensioni limitate del Test Set .

Queste osservazioni hanno motivato l'utilizzo dei sistemi di classificazione multipla che combinano le risposte di un insieme di classificatori.

Un sistema di classificatori multipli è stato implementato con successo al JET e reso disponibile nelle campagne sperimentali, risolvendo il problema della classificazione automatica.

4.1 Selezione dei segnali

Per ciascun impulso prodotto al JET durante le campagne sperimentali viene salvata una grande quantità di dati proveniente sia dai vari sistemi di acquisizione che dai sistemi di controllo.

Esistono due tipi di file di dati: il Jet Pulse File (JPF) e i Processed Pulse File (PPF).

I dati JPF provengono direttamente dai vari sistemi diagnostici, e sono elaborati con una procedura automatica, chiamata Intershot Analysis i cui risultati vengono salvati come file PPF (Figura 4.1).

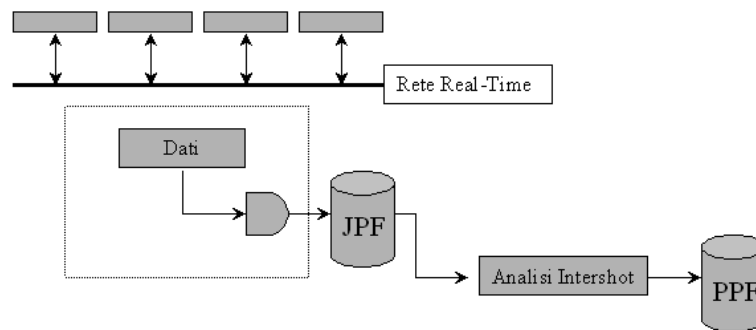


Figura 4.1: Sistema di acquisizione dati al JET

La differenza più rilevante fra i due diversi tipi di dati è che i JPF sono dei segnali molto simili a quelli in real-time (in molti casi sono gli stessi) mentre i PPF differiscono significativamente da quelli presenti in real-time poiché sono elaborati sia con filtri non causali che manualmente.

I segnali selezionati sia per la classificazione che per la predizione sono di tipo JPF. Questo tipo di scelta risponde all'esigenza di poter utilizzare in real-time i tool sviluppati (principalmente quello di predizione).

Sulla base delle precedenti esperienze [31] [32] [35] [36] [37] e di alcune considerazioni fisiche, sono stati selezionati per la descrizione del plasma i seguenti segnali diagnostici:

1. Corrente di plasma	Ipla	[A]
2. Modo bloccato	ML	[T]
3. Densità del plasma	Dens	[n*m ⁻²]
4. Potenza in ingresso	Ptot	[W]
5. Potenza Irradiata	Prad	[W]
6. Beta poloidale	Betap	[AU]
7. Induttanza interna	Lint	[AU]
8. Derivata dell'energia	Dwdt	[W]
9. Posizione verticale del centroide	Posv	[m]
10. Fattore di sicurezza	Q95	[AU]

Questo lavoro di tesi e i precedenti lavori [31] [32] [35] [36] [37] hanno dimostrato che questo set di segnali diagnostici è quello più appropriato per risolvere il problema della classificazione, in quanto essi descrivono completamente lo stato del plasma.

Un'altra importante caratteristica di questo set di segnali è che essi sono delle misure globali dei parametri del plasma, che potrebbero essere opportunamente scalate per ottenere parametri indipendenti dalla macchina su cui sono stati misurati [60]. Infatti questi parametri vengono calcolati in tutte le macchine TOKAMAK e non dipendono da caratteristiche peculiari della macchina stessa.

Per ciascun impulso disrotto la sequenza selezionata come ingresso per i sistemi di classificazione consiste di 3 campioni consecutivi, con un tempo di campionamento di 40 ms; gli istanti di tempo considerati sono: $[t_D-120, t_D-80, t_D-40]$ dove t_D è il tempo di disruzione, cioè quell'istante in cui la corrente di plasma inizia la fase di collasso. La scelta del tempo di campionamento di 40 ms permette la sincronizzazione dei diversi sistemi di acquisizione dati.

Si sono scartati gli ultimi 40 ms prima del tempo di disruzione perché corrispondenti alle fasi di collasso di temperatura e di corrente in cui le misure non sono più attendibili.

L'intervallo di tempo selezionato comprende la fase dei pre-precursori, in cui si dovrebbe assistere alla variazione di un parametro di plasma, causa della disruzione, e parte della fase dei precursori. Queste ipotesi sono state fatte su suggerimento dei fisici, e analizzando alcune prove preliminari, è importante sottolineare che la durata delle fasi di una disruzione non è un valore definito e fisso, ma dipende dal tipo di disruzione, e anche dal tipo di plasma, per cui quello che si è considerato è un intervallo di tempo in cui ipoteticamente dovrebbero essere evidenti le cause di disruzione.

Poiché nella pratica non si è interessati alla classificazione del singolo campione ma alla classificazione dell'impulso, è stato definito un criterio per l'attribuzione dell'impulso alla classe di appartenenza. Per tutti i metodi di classificazione presentati in questa tesi, si è adottato il criterio 'due su tre': ogni impulso viene attribuito alla classe a cui appartengono almeno due campioni su tre.

Questa scelta ha inoltre un importante vantaggio; per la classificazione si vorrebbe prendere in considerazione solo la fase dei pre-precursori, in via ipotetica, ma questa non ha una durata definita e fissa, per cui presumibilmente l'intervallo considerato si sovrapporrà in parte anche alla fase dei precursori oppure si potrebbe sovrapporre a stati di plasma stabili. Queste considerazioni giustificano il fatto che qualche campione può essere confuso ed erroneamente assegnato ad un classe a cui non appartengono gli altri campioni dello stesso impulso.

4.2 Selezione del database

Le campagne sperimentali considerate per la creazione del database sono state effettuate fra Marzo 1999 e Ottobre 2002 (impulsi 47830-57346).

I criteri utilizzati per la selezione degli impulsi disrotti sono: corrente di plasma maggiore di 1.5MA, configurazione in X-point e corrente di plasma al Flat-Top.

Gli impulsi con queste caratteristiche sono quelli di maggiore interesse in quanto le disruzioni che avvengono in plasmi di questo tipo possono mettere a repentaglio l'integrità della macchina. Inoltre queste sono le caratteristiche dei plasmi che verranno realizzati nei reattori di prossima generazione, come ITER.

Sono stati selezionati 324 impulsi, ma di questi solo 146 impulsi sono stati classificati manualmente.

Gli impulsi selezionati e classificati appartengono a 6 classi:

- | | |
|------------------------------|----|
| 1. Modo Bloccato | ML |
| 2. Densità Limite | DL |
| 3. Alta Potenza Radiata | RP |
| 4. Instabilità Verticale | VD |
| 5. Transizione Modo-H/Modo-L | HL |
| 6. Trasporto Interno | IT |

Non è stato possibile classificare alcuni impulsi per i quali i fisici non hanno trovato un accordo sulla classe di appartenenza oppure poiché non presentavano nessuna caratteristica che permettesse una loro attribuzione alle classi selezionate. Per questo motivo nel database è stata inserita la classe dei Non Classificati (UC).

La distribuzione degli impulsi nelle diverse classi è presentata in Tabella 4-1.

Classe	ML	DL	RP	VD	HL	IT	UC
# Impulsi	12	50	5	22	37	5	15

Tabella 4-1: Distribuzione iniziale delle classi di disruzione nel Training Set

Il database è caratterizzato da:

- ✓ Distribuzione degli impulsi fra le classi non uniforme. Alcune classi come le DL sono molto bene rappresentate, mentre altre come le IT non lo sono.
- ✓ Alcuni impulsi Non Classificati.

La distribuzione delle classi nel database, rispecchia il fatto che alcuni tipi di disruzione sono più frequenti di altri.

4.2.1 Classi di disruzione

Le singole classi di disruzione sono brevemente presentate di seguito, con un particolare accento sui segnali che maggiormente le caratterizzano.

Modo Bloccato: Nella struttura magnetica si manifestano di frequente delle perturbazioni MHD derivanti dall'applicazione di un campo magnetico esterno o di correnti instabili oppure di gradienti di pressione, che deformano la struttura del plasma e generano le isole magnetiche, in particolare quelle con $m=2$.

Queste perturbazioni ruotano contemporaneamente attorno al proprio asse ed al toroide. Raggiunto un valore di ampiezza critico, le oscillazioni cessano ma le perturbazioni continuano a crescere e raggiungono dimensioni tali da chiudere un particolare settore del toro e portare a disruzione.

Questo processo è il Modo Bloccato (vedi Par.1.5) [6].

Poiché i Modi Bloccati sono presenti in tutte le disruzioni, la distinzione tra la classe ML e le altre classi di disruzione non è netta; sono inserite nella classe ML tutte le disruzioni, in cui non si ha evidenza di altri fenomeni e la caratteristica dominante è l'aumento del segnale di Modo Bloccato.




Figura 4.2: Esempio di disruzione della classe Modo Bloccato

La Figura 4.2 mostra l'andamento di alcuni segnali negli ultimi secondi di un evento disruttivo. Si può notare la mancanza di eventi particolari nei segnali di potenza radiata o di densità del plasma e l'aumento del segnale di Modo Bloccato.

Densità Limite: le disruzioni per raggiunto limite di densità sono state le disruzioni più studiate in letteratura e sono inoltre le più frequenti.

Esse sono caratterizzate da un incremento della densità durante la fase dei pre-precursori seguito da un immediato aumento della potenza radiata dal plasma.

Il limite di densità non è un valore fisso ma varia a seconda della configurazione del plasma; in particolare è stato dimostrato che il limite aumenta quando vengono applicati

ulteriori riscaldamenti addizionali. Ciò pone un grosso limite allo sviluppo di un modello matematico per la predizione di questo tipo di disruzione.




Figura 4.3: Esempio di disruzione della classe Densità Limite

Nella Figura 4.3 è riportato un esempio di disruzione Densità Limite. Come si può notare, mentre gli altri segnali non subiscono variazioni di rilievo, la densità aumenta lentamente, seguita subito dopo dall'aumento della potenza radiata.

Questo tipo di disruzioni presenta una dinamica più lenta rispetto alle altre.

Alta Potenza Radiata: le disruzioni per Alta Potenza Radiata presentano degli stati del plasma molto simili a quelli presenti nel caso di disruzioni per Densità Limite.

Nel caso di disruzioni per Alta Potenza Radiata, il primo segnale che aumenta (anticipando di pochi ms la densità) è il segnale di potenza radiata. Generalmente questo è legato alla presenza di impurità nel plasma.




Figura 4.4: Esempio di disruzione della classe Alta Potenza Radiata

Nell'esempio riportato in Figura 4.4 si osserva che per pochi millisecondi aumenta solo la potenza radiata, seguita poi dalla densità. In generale, è difficile verificare quale dei due segnali, densità e potenza radiata, aumenti per primo poiché il susseguirsi degli eventi è molto rapido e l'aumento di una delle due grandezze provoca come reazione del plasma un aumento dell'altra.

Instabilità Verticale: questo tipo di disruzione avviene solo in presenza di plasmi elongati.

Questo tipo di configurazione di plasma può essere raggiunta se si applica al plasma un campo magnetico quadrupolare. Questo campo genera però una configurazione verticalmente instabile. Per questo motivo esiste un sistema di controllo ad hoc in grado di controllare la posizione e la velocità verticale del plasma. Se il sistema di controllo fallisce, ad esempio per raggiunti limiti di potenza, il plasma libero di muoversi verticalmente va ad impattare sulla parete interna del reattore, disrompendo per Instabilità Verticale.

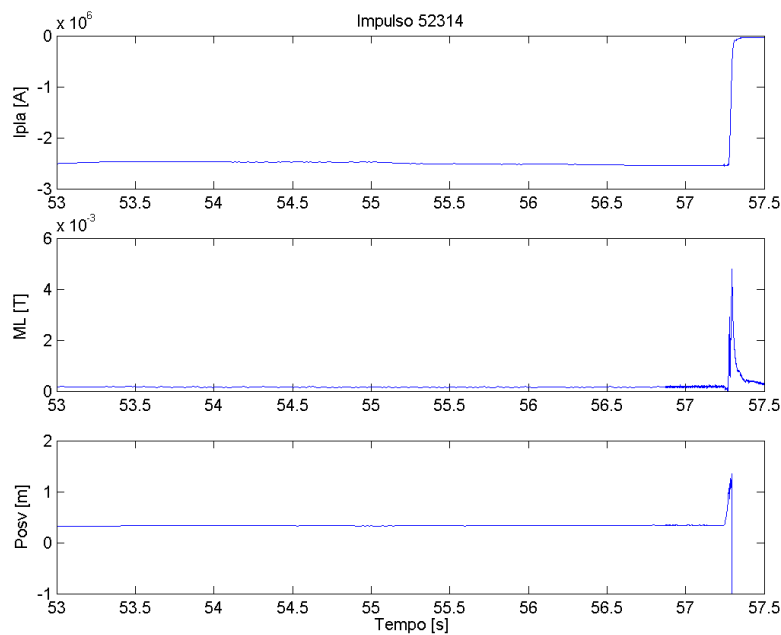


Figura 4.5: Esempio di disruzione della classe Instabilità Verticale

In questo caso è possibile avere un decadimento della corrente sino a 300 MA s^{-1} . Questo tipo di disruzione è quella che maggiormente mette a repentaglio la struttura del reattore. Inoltre è molto rapida e poco prevedibile.

Le disruzioni VI spontanee sono piuttosto rare al JET; quelle presenti nel database sono state tutte provocate dallo stesso sistema di controllo, per cui poco interessanti per questo lavoro di tesi.

In Figura 4.5 sono riportati alcuni segnali significativi per questo tipo di disruzione; si nota solo un picco nel segnale di posizione del centroide del plasma.

Transizione Modo-H/Modo-L: è stato dimostrato e verificato sperimentalmente che superando una certa soglia di potenza in ingresso per mezzo di riscaldamenti ausiliari, il confinamento del plasma migliora in maniera considerevole. Si raggiunge cioè quello che viene chiamato ‘Modo-H’, caratterizzato da alti valori del tempo di confinamento, elevata densità e temperatura (‘high confinement’).

Il ‘Modo-L’, rappresenta invece il normale comportamento del plasma sottoposto ad un riscaldamento ohmico (‘low confinement’).

I plasmi in Modo-H sono però molto difficili da mantenere per motivi di instabilità; pertanto raggiunte certe condizioni è sempre necessario passare al Modo-L.

La classe Modo-H/Modo-L contiene quegli impulsi per i quali la transizione fra i due modi avviene ad elevati valori di densità, normalmente dopo una prematura interruzione di una fonte di calore proveniente da un riscaldamento addizionale.




Figura 4.6: Esempio di disruzione della classe Modo-H/modo-L

Nella Figura 4.6 il segnale di potenza totale diminuisce mentre la densità rimane costante per molto tempo dopo la transizione.

Una transizione da Modo-H a Modo-L deve essere seguita da una diminuzione della densità, infatti i due modi presentano densità limiti differenti, più bassa nel caso del Modo-L, per cui se la densità non diminuisce il limite di densità può essere facilmente raggiunto

Questa classe si differenzia dalla classe Densità Limite, proprio per la particolare situazione in cui il limite di densità viene raggiunto, che presenta stati del plasma molto diversi dal caso precedente.

Trasporto Interno: In alcune circostanze, generalmente quando si opera nella modalità di elevato confinamento (Modo-H) nel plasma si forma una regione in cui il trasporto di particelle e di energia verso l'estremità del plasma diminuisce sensibilmente. Ciò comporta una discontinuità nel gradiente di pressione che subisce un'improvvisa impennata. Tale instabilità, che prende il nome di 'barriera di trasporto interna', si traduce in un rallentamento dell'attività del plasma che conduce a disruzione.

Le disruzioni di questo tipo sono facili da individuare ma il meccanismo con cui queste instabilità si formano non è stato ancora completamente chiarito.

Nell'esempio riportato in Figura 4.7 si noti come una variazione del Beta Poloidale è seguita da un rapido collasso di tutte le altre grandezze presenti in figura.




Figura 4.7: Esempio di disruzione della classe Trasporto Interno

4.3 Training Set

Il database utilizzato per l'addestramento delle reti neurali presenta alcune differenze rispetto a quello inizialmente selezionato.

- ✓ Sono state eliminate dal database le classi Instabilità Verticali e Non-Classificati.
- ✓ Le classi Densità Limite e Alta Potenza Radiata sono state unite in un'unica classe.

In una prima fase del lavoro sono state condotte numerose prove per verificare la possibilità o meno di addestrare i sistemi di classificazione a differenziare queste ultime due classi. Tutti i sistemi di classificazione hanno confuso le disruzioni per Alta Potenza Radiata con quelle per Densità Limite.

Ciò è stato attribuito alla somiglianza tra le due classi ed alla distribuzione degli impulsi; infatti mentre la classe Densità Limite è presente nel database con un numero consistente di esempi, la classe Alta Potenza Radiata, è molto poco rappresentata.

Il database risultante utilizzato per addestrare i classificatori è composto da 109 impulsi con la distribuzione nelle classi presentata in Tabella 4-2.

Classe	ML	DL/RP	HL	IT
# Impulsi	12	55	37	5

Tabella 4-2: Distribuzione finale delle classi di disruzione nel Training Set

4.4 Selezione del Test Set

Per confrontare i risultati ottenuti con le diverse tecniche sviluppate è stato selezionato un Test Set.

Il Test Set è stato costruito selezionando 20 impulsi appartenenti a campagne sperimentali non comprese nel Training Set.

La distribuzione fra le diverse classi nei 20 impulsi di Test è presentata in Tabella 4-3.

Classe	ML	DL/RP	HL	IT
# Impulsi	6	7	2	5

Tabella 4-3: Distribuzione delle classi di disruzione nel Test Set

Il Test Set è particolarmente esiguo perciò il numero di impulsi per il Test non è sufficiente a garantire le capacità di generalizzazione del classificatore. Di contro però il Test Set risulta temporalmente separato dal Training Set. Poiché il JET è una macchina sperimentale, lo scopo dell'esperimento, le configurazioni di plasma, i parametri caratteristici della macchina variano nelle diverse campagne sperimentali.

Ciò rende il Test Set selezionato sufficientemente 'diverso' dal Training Set.

5. APPROCCI ALLA CLASSIFICAZIONE E RISULTATI

In questo capitolo sono descritti i dettagli implementativi dei tre approcci alla classificazione delle disruzioni ed i loro relativi risultati. Si presentano alcune considerazioni sul database, ed i suoi limiti messi in luce dall'analisi dei risultati, e sui segnali diagnostici utilizzati per classificare.

Per misurare le prestazioni dei classificatori, i risultati dei classificatori sono stati confrontati con quelli ottenuti con una tecnica statistica standard, k-Nearest Neighbour.

5.1 Multi Layer Perceptron

Le reti Multi Layer Perceptron sono state addestrate utilizzando il Matlab Neural Network Toolbox [44]. L'algoritmo di addestramento utilizzato è l'algoritmo di Levenberg-Marquardt, che implementa la variazione di Levenberg-Marquardt al metodo di Newton. Esso produce i migliori risultati in termini di errore e di velocità di addestramento.

Il modello neurale è composto da 10 neuroni nello strato di ingresso, 2 neuroni nello strato di uscita e funzioni di attivazione logistiche sigmoidali.

L'ingresso della rete è costituito dal valore dei 10 segnali diagnostici caratterizzanti lo stato del plasma relativi allo stesso istante di tempo.

L'uscita della rete MLP è di tipo binario, allo scopo di ridurre al minimo il numero di neuroni e quindi di parametri liberi della rete, in considerazione del limitato numero di esempi a disposizione. I due neuroni nello strato di uscita del MLP codificano le quattro classi di disruzione. La Tabella 5-1 riporta la corrispondenza fra codice binario e classe di disruzione.

Classe	Codifica
ML	01
IT	00
DL/RP	11
HL	10

Tabella 5-1: Codifica dell'uscita della rete MLP

La rete è stata addestrata con tre pattern per ciascun impulso, corrispondenti agli istanti 40 ms, 80 ms, 120 ms, prima del tempo di disruzione. La rete MLP produce un'uscita per ciascun pattern composto da due digit binari che identificano la classe di disruzione.

L'uscita di ciascun neurone dello strato di uscita è confrontato con un valore di soglia settato a 0.5 e posta uguale a 1 se è maggiore o uguale al valore 0.5, mentre è posta uguale a zero nel caso in cui sia minore. Con questa codifica, per ciascun impulso disrotto, l'uscita della rete MLP è composta da tre patterns di due digit binari ciascuno.

Un impulso è assegnato alla classe K se almeno due dei tre patterns sono associati alla classe K . Se i tre campioni risultano in totale disaccordo, l'impulso non è classificato.

La Figura 5.1 mostra un esempio di codifica per un impulso: l'uscita della rete per i tre patterns e la risposta del sistema di classificazione.

La topologia della rete MLP è stata selezionata mediante una procedura di 'trial and error'. Allo scopo sono state addestrate numerose reti facendo variare sia il numero degli strati nascosti che il numero di neuroni per ogni strato nascosto.

Inoltre, per evitare il problema dei minimi locali, sono state effettuate diverse sessioni di addestramento per ciascuna topologia, con una inizializzazione random dei pesi della rete MLP per ciascuna sessione.




Figura 5.1: Uscita del classificatore MLP (Impulso n°52105 - ML)

Per evitare l'over-fitting, il Training Set iniziale, composto da 109 impulsi disrotti, è stato diviso in due set separati:

- ✓ Il Training Set è composto dall'80% degli impulsi di ogni singola classe (88 impulsi per un totale di 264 campioni);
- ✓ Il Validation Set è composto dal 20% degli impulsi per ogni singola classe, (21 impulsi per un totale di 63 campioni).

In Tabella 5-2 è indicata la distribuzione fra le classi di disruzione.

	ML	DL/RP	HL	IT
Training Set	10	44	30	4
Validation Set	2	11	7	1

Tabella 5-2: Distribuzione delle classi fra Training Set e Validation Set

I migliori risultati sono stati ottenuti con la seguente architettura neurale:

- 10 neuroni nello strato di ingresso;
- 5 neuroni nello strato nascosto;

- 2 neuroni nello strato di uscita.

La rete presenta 70 parametri. I risultati sul Training Set, Validation Set, e Test Set sono riportati in Tabella 5-3, in termini di numero di impulsi non correttamente classificati dal sistema di classificazione.

Training Set	Validation Set	Test Set
0/88	0/21	1/20

Tabella 5-3: Performance della migliore rete MLP in termini di numero di impulsi non correttamente classificati

La Tabella 5-4 riporta i risultati in termini di numero di campioni erroneamente classificati.

Training Set	Validation Set	Test Set
4/264	2/63	4/60

Tabella 5-4: Performance della migliore rete MLP in termini di numero di campioni erroneamente classificati

I risultati sui campioni ci garantiscono che la rete MLP selezionata non ha imparato esclusivamente il Training Set.

La rete MLP classifica in modo non concorde con la classificazione umana solo l'impulso numero 53535. Tale impulso appartiene alla classe ML, ma viene classificato come HL per due campioni su tre e come ML per il restante campione.

Il risultato ottenuto è piuttosto robusto. Più del 10% delle reti addestrate presenta risultati simili a quelli della migliore rete selezionata (stesse percentuali di errore sul Training Set e Validation Set).

5.1.1 Analisi di salienza

L'analisi di salienza risponde all'esigenza di individuare l'importanza relativa dei diversi segnali di ingresso in termini degli effetti che ciascuno di essi ha sulla funzione di errore [61] della rete. Essa consiste nel rimuovere uno o più segnali di ingresso e valutare le performance del sistema. La natura distribuita della struttura neurale permette di eliminare uno o più ingressi ed ottenere ancora una risposta dalla rete.

Nella Tabella 5-5 sono riportati gli errori commessi sugli impulsi del Test Set, nelle diverse classi, ottenuti azzerando un segnale di ingresso alla volta.

	DL/RP	ML	IT	HL	TOT
<i>Ipla</i>	0/7	1/6	3/5	0/2	4/20
<i>ML</i>	0/7	2/6	1/5	0/2	3/20
<i>Dens</i>	0/7	5/6	3/5	0/2	8/20
<i>Prad</i>	1/7	5/6	4/5	0/2	10/20
<i>Betap</i>	2/7	2/6	1/5	1/2	6/20
<i>Ptot</i>	0/7	2/6	2/5	0/2	2/20
<i>Lint</i>	2/7	1/6	5/5	1/2	9/20
<i>Dwdt</i>	0/7	1/6	1/5	0/2	2/20
<i>Posv</i>	1/7	3/6	1/5	0/2	4/20
<i>q95</i>	2/7	1/6	1/5	2/2	6/20
<i>Tot</i>	8	23	22	4	

Tabella 5-5: Analisi di salienza del Test Set per la migliore rete MLP

Risulta evidente che i segnali che hanno una maggiore influenza sulla classificazione sono: la potenza radiata, l'induttanza interna del plasma e la densità del plasma.

Le classi Modo Bloccato e Trasporto Interno risultano quelle maggiormente sensibili rispetto ad un azzeramento di uno qualunque dei segnali. Ciò implica che per queste due classi il legame tra i segnali diagnostici e la classe di appartenenza coinvolge tutti i segnali in ingresso alla rete.

5.2 Support Vector Machines

Le Support Vector Machines (SVM) rappresentano una tecnica di classificazione alternativa alle reti Multi Layer Perceptron.

I classificatori non lineari SVM sono stati addestrati utilizzando OSU SVM Classifier Matlab Toolbox (ver. 3.00) basato sulla versione 2.33 di LIBSVM [62]; LIBSVM è una libreria software per la classificazione e la regressione con le Support Vector Machines, che implementa gli algoritmi di addestramento sviluppati da Vapnik [51].

L'ingresso è costituito dai 10 segnali diagnostici, normalizzati nell'intervallo [0,1]; sono state fatte alcune prove anche normalizzando tra [-1,1] come per le reti MLP, ottenendo risultati peggiori.

L'uscita della rete è costituita da un numero reale che identifica la classe di appartenenza. Anche in questo caso, un impulso viene assegnato alla classe K se almeno due campioni su tre sono attribuiti alla classe K .

La Tabella 5-6 indica la distribuzione del database fra Training e Test Set.

	ML	DL/RP	HL	IT	Tot
Training Set	12	55	37	5	<u>109</u>
Test Set	6	7	2	5	<u>20</u>

Tabella 5-6: Distribuzione delle classi fra Training Set e Test Set

Per selezionare il Kernel più adatto al problema di classificazione delle disruzioni, sono stati testati sia Kernel polinomiali (grado del polinomio p variabile tra 2 e 7) sia i Kernel Radial Basis Function ($\sigma \in [1-100]$ con passo di discretizzazione uguale a 0.05) al variare della funzione d'errore C .

5.2.1 Support Vector Machines- Risultati

I risultati migliori che rappresentano il risultato di compromesso fra gli errori sul Training Set e quelli sul Test Set, sono stati ottenuti con i Kernel Radial Basis Function con $C=1$ e $\sigma=1.35$. Un aumento della funzione d'errore provoca un miglioramento nelle performance del Training Set ed un peggioramento nelle performance del Test Set.

La Support Vector Machine ha selezionato 158 vettori di supporto su un totale di 327 campioni, cioè il 48% dei campioni è stato utilizzato dall'algoritmo di ottimizzazione per definire le superfici di separazione fra le classi di disruzione.

La Tabella 5-7 mostra le performance del classificatore SVM in termini di numero di impulsi del Training Set e del Test Set non correttamente classificati.

Training set	Test set
9/109	3/20

Tabella 5-7: Performance della migliore rete SVM

Le performance del classificatore SVM sono peggiori rispetto a quelle del classificatore MLP.

Se si considera la distribuzione degli errori fra le varie classi, riportata in Tabella 5-8 si può osservare che la classe più difficile da classificare risulta, come nelle MLP, la classe ML, seguita dalla classe IT.

	DL/RP	ML	IT	HL
Training set	0/55	6/12	2/37	1/5
Test set	0/7	3/6	0/5	0/2

Tabella 5-8: Distribuzione degli errori fra le classi della migliore SVM

5.2.2 Analisi del Test Set

Per verificare se impulsi contenuti del Test Set contenessero informazioni fondamentali per il calcolo delle superfici di separazione fra le classi, è stata fatta una prova ulteriore.

E' stata addestrata una SVM con un Training Set composto da tutti i 129 impulsi.

In questo caso, i tre impulsi del Test Set classificati in modo scorretto dal classificatore SVM sono stati selezionati come vettori di supporto. La loro presenza nel Training Set sposta quindi i confini delle superfici di separazione.

In particolare sono selezionati come vettori di supporto tutti e tre i campioni di due impulsi, e i primi due campioni per il terzo impulso (cioè i campioni in t_d-120 ms e t_d-80 ms). Ciò indica la novità del Test Set nei confronti del Training Set e la necessità di ridefinire le superfici di separazione fra le classi per classificare correttamente i tre impulsi di Test.

Inoltre in quest'ultima prova i campioni selezionati come vettori di supporto sono 195 su 387 (50.3%). La percentuale di campioni selezionati è ora maggiore rispetto alle prove precedenti, indicando la novità del Test Set rispetto al Training Set.

5.2.3 Analisi dei segnali

Per analizzare l'importanza dei singoli segnali diagnostici nel processo di classificazione, sono stati addestrati dei classificatori SVM con i parametri del miglior classificatore ottenuto ($C=1$, $\sigma=1.35$), ma con un numero variabile di segnali in ingresso.

Le prove sono state effettuate partendo da un unico segnale e aumentando progressivamente il numero dei segnali.

Nella Figura 5.2 sono riportati i risultati ottenuti in termini di errori sul Training Set ed errori sul Test Set.

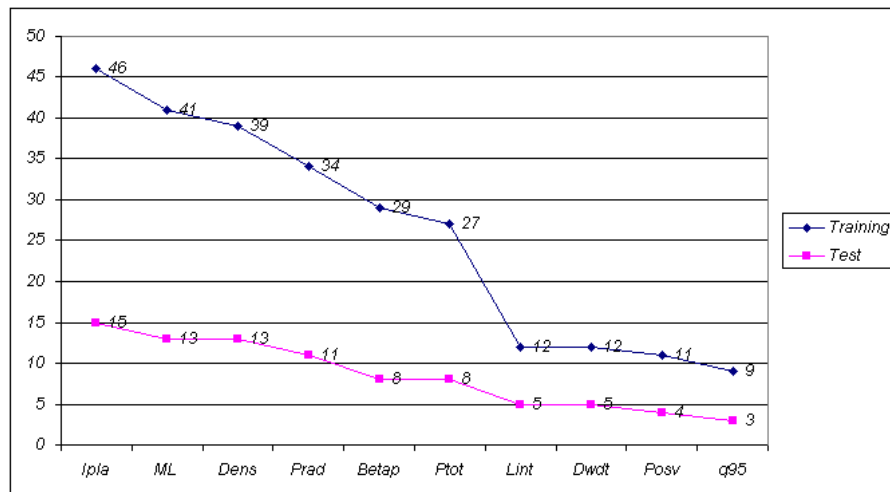


Figura 5.2: Errori nel Training Set e nel Test Set al variare del numero dei segnali di ingresso

Come si può notare, l'introduzione della derivata dell'energia non provoca nessuna variazione negli errori del Training Set e del Test Set. I maggiori decrementi dell'errore sono associati all'introduzione del segnale di induttanza interna del plasma, di beta poloidale e di potenza radiata.

Sono state fatte ulteriori prove considerando dei sottoinsiemi dei segnali diagnostici, costituiti da quelli che nelle precedenti prove hanno dimostrato di essere i più significativi; i risultati più interessanti sono stati riportati in Tabella 5-9.

	Training Set	Test Set
<i>Ipla-ML-Betap-Lint-q95</i>	14/109	5/20
<i>Ipla-ML-Dens-Betap-Lint-q95</i>	12/120	4/20
<i>Ipla-ML- Dens -Prad- Betap-Lint-q95</i>	10/120	4/20

Tabella 5-9: Errori sul Training Set e sul Test Set con set di segnali ridotto

Con soli 6 o 7 segnali si ottiene un errore maggiore ma dello stesso ordine rispetto al caso di 10 segnali in ingresso.

5.3 Self Organizing Maps

Le Self Organizing Maps sono state utilizzate per valutare l'esistenza di un legame fra clusters autonomamente identificati dalle SOM e le differenti classi di disruzione.

Per addestrare le SOM si è utilizzato il Som_pak Toolbox di Matlab realizzato dall'Università di Helsinki [63] [64].

Sono state effettuate diverse prove per tarare diversi parametri della rete come le dimensioni della mappa (numero di neuroni), il range di normalizzazione, la funzione di vicinato ed il numero di segnali in ingresso.

La procedura utilizzata per addestrare la mappa e definire la corrispondenza mappa SOM e classi di disruzione, consta di due step:

- ✓ La SOM individua le regolarità statistiche presenti nel database;

- ✓ L'algoritmo K-means, sulla base della topologia e della configurazione assunta dalla mappa SOM, divide quest'ultima in un numero massimo di cluster (più ampi del singolo neurone) fissato in anticipo.

L'algoritmo K_means è un algoritmo di clustering non-neurale. L'idea è quella di trovare la migliore partizione di un numero N di patterns in K classi, in maniera tale da minimizzare la distanza fra ciascun pattern in ingresso ed il centro di ciascuna classe.

Il metodo richiede che venga indicato il numero massimo di clusters. Esso presenta buone proprietà di convergenza, infatti converge in poche iterazioni durante le quali si ricalcola il centro di ogni gruppo/cluster. Il processo termina quando i centri sono stabili e la partizione non si modifica più in maniera significativa.

5.3.1 Self Organizing Maps –Risultati

I risultati migliori sono stati ottenuti normalizzando i segnali in ingresso nel range [0,1].

Nel primo step si è ottenuta una mappa 11x9, per un totale di 99 neuroni.

Nel secondo step, l'algoritmo K_means, applicato alla mappa precedentemente ottenuta, associa a ciascun neurone la classe a cui appartengono la maggior parte degli impulsi contenuti nel cluster.

Gli errori commessi dalla mappa SOM sono riportati in Tabella 5-10. La mappa ottenuta è riportata in Figura 5.3.

Training Set	Test Set
26/109	8/20

Tabella 5-10: Performance della migliore SOM




Figura 5.3: Mappa SOM

Come si può notare:

- ✓ Esistono due cluster che possono essere facilmente associati rispettivamente alla classe DL (in basso a sinistra) e alla classe HL (in alto a destra);
- ✓ Tutti gli impulsi IT sono raggruppati in un unico cluster (3 neuroni in alto a destra);
- ✓ Le ML sono scarsamente localizzate e non esiste un gruppo predominante.

5.4 k-Nearest Neighbour

La k-Nearest Neighbour (k-NN) è una tecnica di classificazione statistica non parametrica diventata negli ultimi anni un metodo standard con cui si confrontano tutti i nuovi classificatori.

La fase di addestramento di un classificatore k-NN consiste nella memorizzazione di tutto il Training Set.

Quando un vettore in ingresso sconosciuto deve essere classificato, si calcolano le distanze fra questo vettore e tutti quelli di Training Set e si individuano i k (parametro fissato dal progettista) vettori in ingresso più vicini.

Il criterio di scelta della classe di appartenenza è quello della maggioranza assoluta (majority rule), cioè il pattern viene assegnato alla classe C_k se a questa classe appartengono la maggior parte dei K esempi più vicini nello spazio degli ingressi. Solitamente la metrica utilizzata è la distanza euclidea.

Poiché il criterio di decisione della classe è basato sulla maggioranza assoluta, il valore di k deve essere un numero dispari.

Malgrado questo algoritmo sia particolarmente semplice, esso gode di una importante proprietà: è un classificatore ottimo nel caso asintotico, cioè nel caso in cui il numero degli esempi del Training Set tenda ad infinito [40].

Il maggior problema dell'algoritmo k-NN è la complessità computazionale e l'occupazione di memoria, dovuta al considerevole numero di distanze da calcolare.

E' stato considerato un valore di k variabile tra 1 e 19, considerando solo i valori dispari. I migliori risultati sono stati ottenuti con $k=3$ (vedi Tabella 5-11).

Training Set	Test Set
4/109	7/20

Tabella 5-11: Performance del migliore classificatore k-NN

Dall'analisi dei risultati è possibile affermare che la distribuzione degli impulsi è sufficientemente complessa e irregolare da invalidare un approccio basato su algoritmi semplici e di immediata applicazione come k-NN.

6. I SISTEMI DI CLASSIFICAZIONE MULTIPLA

Nell'ultimo decennio è cresciuto l'interesse nei confronti di un nuovo approccio alla classificazione, basato sul fatto che classificatori diversi commettono solitamente errori diversi, ovvero ognuno di essi presenta prestazioni migliori in determinati sottoinsiemi dello spazio delle features. Se tali sottoinsiemi sono sufficientemente distinti, si può trarre vantaggio dall'utilizzazione congiunta delle informazioni provenienti da classificatori diversi, in modo da sfruttare i punti di forza di ciascuno di essi.

Di seguito verrà fatta una breve descrizione dei sistemi di classificazione multipla, verrà presentato il tool di classificazione per le disruzioni basato su insiemi di classificatori MLP e la sua implementazione inter-shot al JET.

L'approccio sinora seguito nel progettare un sistema di classificazione automatica delle disruzioni presenta alcuni punti critici.

Il problema fondamentale di questo tipo di approccio risiede nella difficoltà di stimare l'errore di generalizzazione dei classificatori, cioè l'effettiva probabilità di errore (di cui l'errore commesso su un Test Set di dimensioni finite costituisce soltanto un'approssimazione). In particolare, nel caso in esame, le dimensioni limitate del Test Set non sono sufficienti per poter stabilire se il classificatore che ha dato i risultati migliori in fase di valutazione sia effettivamente superiore agli altri.

Inoltre questo metodo non permette di sfruttare la complementarietà dei classificatori, cioè il fatto che diversi classificatori commettono solitamente errori diversi: per ognuno di essi esiste una classe o un insieme di classi i cui patterns vengono classificati con maggiore accuratezza. Il classificatore MLP precedentemente individuato con le migliori prestazioni globali non ha necessariamente le migliori prestazioni locali in tutte le regioni dello spazio delle features.

6.1 Insiemi di classificatori

L'idea di utilizzare contemporaneamente un sistema di metodi più o meno equivalenti per la soluzione di un problema complicato (ridondanza) è comune a tutte le discipline in cui ha notevole importanza costruire un sistema affidabile.

Nel campo della pattern recognition la combinazione di classificatori multipli è stata introdotta all'inizio degli anni '90: nel 1990 Hansen e Salamon [65] hanno proposto di utilizzare insiemi di reti neurali osservando che diverse configurazioni di rete hanno un'alta probabilità di commettere errori in diversi sottoinsiemi dello spazio degli ingressi. Da allora, sono stati proposti in letteratura diversi criteri per la combinazione delle uscite dei singoli classificatori. Essi possono essere distinti sulla base della loro complessità. I criteri *semplici* [66] si basano su regole di combinazione 'fisse' come il majority voting [67] o la media semplice [68]. I criteri *complessi* usano tecniche adattative o basate sulla conoscenza (addestrabili) come il voting pesato [69] o il Behaviour Knowledge space rule [70].

Riassumendo: le motivazioni principali che hanno portato all'uso dei classificatori multipli MLP sono:

- ✓ Difficoltà nell'individuazione del miglior classificatore MLP; infatti molte reti, anche con architetture differenti, presentavano le stesse performance sul Training Set e sul Validation Set;
- ✓ Possibilità di sfruttare la complementarità dei classificatori MLP;
- ✓ Rendere il tool di classificazione più affidabile attraverso un sistema ridondante.

6.2 Caratteristiche principali di un sistema di classificatori

I modelli di classificatori multipli possono essere suddivisi in base alla modalità di combinazione, che può essere:

1. Modulare;
2. Basata su insiemi.

L'approccio modulare prevede la decomposizione del problema in un certo numero di sottoproblemi, per ognuno dei quali viene costruito uno specifico classificatore. La soluzione del problema globale è data dall'unione dei contributi di ciascun classificatore.

L'approccio basato su insiemi, che è quello utilizzato in questo caso, consiste invece nella costruzione di più classificatori ridondanti: le soluzioni così determinate vanno poi opportunamente combinate per ottenere una soluzione definitiva (decision fusion).

Lo schema di principio di un classificatore multiplo basato su insiemi è mostrato in Figura 6.1.




Figura 6.1: Classificatore multiplo basato su insiemi

Possiamo inoltre distinguere i sistemi di classificazione multipla in base all'architettura:

1. Seriale
2. Ibrida

3. Parallela

L'architettura seriale è collegata alla classificazione con opzione di rigetto: ogni classificatore riceve in ingresso i pattern rigettati dal classificatore precedente, cosicché l'insieme dei patterns viene ridotto ad ogni passo.

L'architettura parallela prevede invece che tutti i classificatori dell'insieme operino contemporaneamente: la decisione finale si ottiene combinando le uscite con un'opportuna funzione di combinazione.

Nel seguito l'attenzione sarà focalizzata su questa tipologia di architettura, il cui schema di principio è mostrato in Figura 6.2.

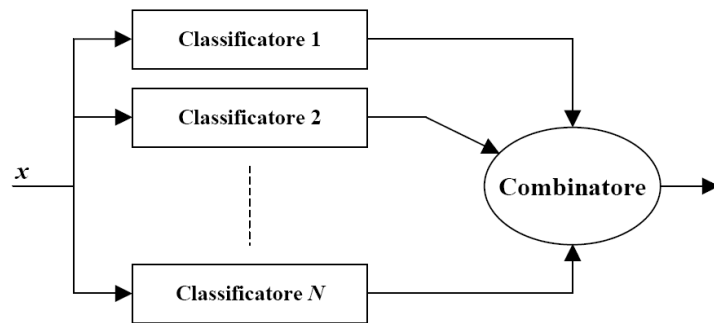


Figura 6.2: Schema di un MCS ad architettura parallela

6.3 Progetto del sistema di classificatori multipli

Il progetto del sistema di classificatori multipli è stato suddiviso in due fasi principali:

- ✓ Addestramento dei classificatori;
- ✓ Determinazione della funzione di combinazione.

I cinque classificatori selezionati tra i classificatori con le prestazioni migliori presentano due importanti caratteristiche:

1. Commettono errori su campioni diversi;
2. Presentano un diverso numero di neuroni nello strato nascosto (da 5 a 10 neuroni).

Le uscite dei classificatori sono state combinate per mezzo di due regole di decision fusion molto semplici: majority voting con opzione di rigetto e media semplice.

Majority voting con opzione di rigetto: il pattern viene assegnato alla classe per cui ha deciso la maggioranza assoluta degli R classificatori (in questo caso $R=5$). Se la maggioranza assoluta non viene raggiunta l'impulso è rigettato.

Media semplice: è la regola più semplice per la combinazione di classificatori le cui uscite siano distribuite con continuità in un certo intervallo (soft output).

La tecnica consiste nel calcolare la media delle uscite dei singoli classificatori:

$$p(j) = \frac{1}{R} \sum_{i=1}^R p_i(j), \forall j = 1, \dots, K \quad (6.1)$$

dove K è il numero delle classi possibili e R il numero totale dei classificatori.

6.4 Risultati

Le tecniche di decision fusion, majority voting con opzioni di rigetto e media semplice, sono state applicate ad un insieme di cinque classificatori.

La Tabella 6.1 riporta gli errori sul Training Set e sul Test Set dei singoli classificatori e del sistema di classificazione che implementa il Majority Voting con opzione di Rigetto (MVR). In questo caso il Training Set contiene 109 impulsi (l'unione del Training Set e del Validation Set del MLP).

Nella prima colonna della tabella è indicato il numero di neuroni nello strato nascosto di ciascun classificatore MLP.

Rete	# Neuroni	Traning Set	Test Set
1	5	0/109	1/20
2	7	0/109	1/20
3	8	4/109	0/20
4	9	0/109	1/20
5	10	0/109	1/20
MVR		0/109	0/20

Tabella 6-1: Performance del sistema di classificatori multipli

Il sistema di classificatori multipli ha permesso di:

- ✓ Migliorare le performance del migliore classificatore MLP;
- ✓ Rendere il tool di classificazione più affidabile.

Il sistema di classificatori multipli è stato poi utilizzato per classificare altri 125 impulsi di cui non è nota la classe di appartenenza, che erano stati precedentemente selezionati.

In questo caso si è potuto solo confrontare la distribuzione degli impulsi fra le classi.

In Figura 6.3 sono riportate le percentuali di distribuzione fra le classi di disruzione per il set di impulsi classificati (129 impulsi) e per il set di impulsi non classificati (125 impulsi).

Dal confronto si può notare un sostanziale accordo tra le due distribuzioni.




Figura 6.3: Confronto delle percentuali di distribuzione fra 129 impulsi classificati e 125 impulsi non classificati

Un'analisi approfondita di questo risultato è stata fatta da alcuni fisici, seppur non classificando un impulso alla volta ma solo considerato i tipi di impulso che avevano disrotto e lo scopo dell'impulso stesso. Questa analisi ha giustificato l'assenza totale di disruzione di tipo IT e le differenze fra le due distribuzione di impulsi, valutando perciò attendibile la classificazione ottenuta mediante il tool di classificazione.

Un'altro indicatore dell'affidabilità dei risultati ottenuti sugli impulsi non classificati è dato dalle percentuali di voto, cioè il grado di accordo tra i cinque classificatori.

Impulsi con	Percentuali
5 voti su 5	52,0%
4 voti su 5	29,6%
3 voti su 5	15,2 %
Impulsi rigettati	3,2%

Tabella 6-2: Percentuali di voto degli impulsi non classificati

Come si può notare la percentuale degli impulsi che non hanno ricevuto la maggioranza assoluta e sono stati rigettati è molto bassa, in totale quattro impulsi rigettati su 125, mentre più della metà degli impulsi è stato classificato con la maggioranza assoluta dei voti.

6.5 Implementazione

Il sistema di classificatori multipli, la cui uscita è combinata mediante il majority voting con opzione di rigetto, è stato implementato al JET. Il codice è scritto in linguaggio C++, e vi si accede mediante una semplice interfaccia grafica.

Questo tool permette di classificare tutte le disruzioni che sono memorizzate nel database del JET.

Un esempio della finestra del programma è riportato in Figura 6.4.

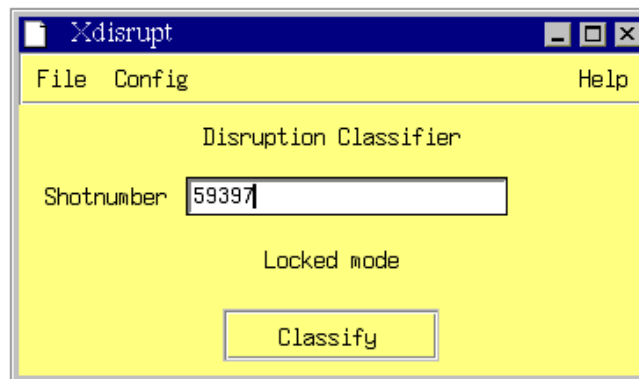


Figura 6.4: Interfaccia grafica del tool di classificazione implementato al JET

7. CLASSIFICAZIONE DI DISRUZIONI - CONCLUSIONI

L'obiettivo di questa prima parte di lavoro di tesi è stato la progettazione e la successiva implementazione di un classificatore automatico di disruzioni.

Sono state sviluppate diverse tecniche di classificazione e clusterizzazione e confrontate analizzando i risultati ottenuti su un Test Set.

A causa delle ridotte dimensioni del Test Set si è effettuata un'analisi di tutti gli aspetti che possono essere considerati degli indicatori della bontà ed affidabilità dei risultati ottenuti. Tutte le tecniche hanno indicato la classe Modo Bloccato come quella più difficile da individuare perché presenta molte caratteristiche in comune con le altre classi. Gli impulsi appartenenti a questa classe sono la maggiore fonte di errore per le tecniche di classificazione, mentre le tecniche di clusterizzazione tendono a distribuire questi impulsi in tutto lo spazio delle uscite, indicando la non uniformità di caratteristiche di questa classe di disruzione.

Al contrario, le altre tre classi risultano ben definite e separate sia nello spazio degli ingressi, come rilevato dalle Self Organizing Maps, sia nello spazio delle feature, come si evince dai risultati delle Multi Layer Perceptron e delle Support Vector Machines.

Dalle prove effettuate il miglior classificatore di disruzioni è risultato essere il Multi Layer Perceptron. La rete Multi Layer Perceptron non solo presenta buoni risultati in fase di test, ma questo tipo di classificatori si sono rivelati particolarmente robusti. Infatti un gran numero di reti presenta buone percentuali di errore nel Training Set e nel Validation Set.

I risultati ottenuti con le altre tecniche testate sono riconducibili a limiti degli algoritmi di addestramento.

L'algoritmo alla base delle Self Organizing Maps ha l'obiettivo di determinare dei cluster in una distribuzione di dati in ingresso. L'insieme dei cluster determinato deve

essere tale che dati appartenenti ad uno stesso cluster siano quanto più simili possibile e dati appartenenti a cluster lontani siano quanto più dissimili. In questo caso è stata utilizzata la metrica euclidea come misura di similarità. Un tale criterio non si è rivelato adatto alla classificazione di disruzioni. Il legame fra segnali diagnostici per impulsi appartenenti alla stessa classe di disruzione non è esclusivamente di tipo geometrico ma coinvolge relazioni non lineari che necessitano di un modello più complesso.

La tecnica k-NN assegna la classe d'appartenenza del campione testato in base alla distanza euclidea di questo dagli esempi inseriti in memoria, ma anche in questo caso una tecnica basata esclusivamente sul criterio di prossimità nello spazio degli ingressi non è sufficiente a classificare correttamente le disruzioni.

Le Support Vector Machines si basano su una combinazione lineare di Kernel, che hanno un supporto locale e limitato, quindi presentano valori che tendono a zero quando ci si allontana dai punti di massimo. Nel caso preso in esame i punti del Test Set, come verificato dalla prova presentata nel Par.5.2.2, cadono in regioni delle features lontane da quelle del Training Set. Infatti la loro presenza in fase di addestramento ha provocato una ridefinizione delle superfici di separazione, e per questo vengono classificati in modo scorretto.

E' stata inoltre verificata l'efficacia di due tecniche per la combinazione delle uscite di un insieme di classificatori.

L'uso di un classificatore multiplo, costituito da cinque classificatori opportunamente selezionati, ha permesso di migliorare le performance del miglior classificatore Multi Layer Perceptron e di rendere il tool di classificazione nel suo complesso più affidabile, passaggio indispensabile per la successiva implementazione come strumento di analisi delle disruzioni in servizio al JET.

Anche in questo caso, non essendo disponibile un cospicuo Test Set, l'affidabilità del sistema di classificatori multipli è stata misurata anche mediante tecniche non convenzionali basate sull'esperienza e su evidenze sperimentali, come il test presentato

nel Par. 6.4, dove i dati non classificati manualmente hanno presentato una distribuzione fra le classi simile a quella dei dati classificati manualmente.

Il lavoro si è ritenuto concluso in maniera soddisfacente. Il tool è stato implementato al JET e si sta dimostrando un'utile strumento di analisi per gli utenti del settore.

8. PREDIZIONE DELLE DISRUZIONI

La seconda parte del lavoro di tesi è incentrata sulla progettazione e successiva implementazione di un tool per la predizione di disruzioni, cioè di un sistema in grado di predire l'approssimarsi di una disruzione sufficientemente in anticipo, durante il funzionamento della macchina.

Per quanto il tool di classificazione delle disruzioni possa essere un strumento utile e importante per migliorare la normale gestione operativa della macchina, esso non risolve il problema delle disruzioni durante le campagne sperimentali, che proprio per il loro carattere sperimentale devono poter essere condotte esplorando tutti i possibili spazi operativi della macchina in assoluta sicurezza. Al momento vengono posti dei limiti operativi per evitare di incorrere in una disruzione durante un esperimento. Malgrado questi limiti siano molto restrittivi, essi non assicurano l'eliminazione di questo fenomeno.

L'eliminazione o quantomeno la mitigazione degli effetti distruttivi di una disruzione è fondamentale soprattutto per i TOKAMAK di prossima generazione, come ITER, per cui sono previsti carichi termici durante una disruzione in grado di fare evaporare o fondere il materiale del divertore sino a profondità di 10-100 μm .

E' necessario perciò disporre nelle macchine TOKAMAK di un sistema di predizione di disruzioni, in grado di dare l'allarme dell'approssimarsi di un fenomeno distruttivo con sufficiente anticipo. Tale sistema utilizzato in congiunzione con l'esistente procedura di spegnimento rapido del plasma, o con nuovi sistemi di mitigazione al momento allo studio [33], come le valvole rapide di mitigazione, consentirebbe di evitare le disruzioni, o quantomeno mitigarne i disastrosi effetti.

Un sistema di predizione di disruzioni deve possedere alcune caratteristiche che devono essere considerate in fase di progettazione:

- ✓ La percentuale di impulsi disrotti correttamente predetti deve essere superiore a quella dei sistemi di allarme già esistenti nella macchina;
- ✓ La predizione deve essere fatta sufficientemente in anticipo rispetto al collasso completo del plasma, per consentire sia ai sistemi di mitigazione che a quelli di spegnimento di completare le rispettive procedure;
- ✓ Il numero dei Falsi Allarmi deve essere limitato;
- ✓ Il sistema di predizione deve essere in grado di predire i diversi tipi di disruzione caratterizzati da fenomeni e dinamiche differenti;
- ✓ Il sistema di predizione deve esser applicabile in real-time.

Il sistema di predizione proposto in questo lavoro rappresenta una soluzione di compromesso fra le diverse esigenze sopra elencate, alcune delle quali contrastanti. Ad esempio, ad un aumento della percentuale di disruzioni correttamente predette corrisponde un aumento della percentuale dei Falsi Allarmi [35].

Un punto sensibile nella progettazione di un sistema di predizione di tipo neurale, ma in generale di un sistema di predizione di questo tipo di fenomeno, è l'identificazione delle due fasi iniziali di una disruzione, la fase dei pre-precursori e la fase dei precursori.

In riferimento alla Figura 1.8, dove vengono riportate le fasi della disruzione, il sistema di predizione dovrebbe essere il grado di identificare il passaggio dalla fase dei pre-precursori a quella dei precursori.

Queste fasi non hanno però durata definita e al momento non si conoscono degli indicatori di un avvenuto passaggio da una fase all'altra, come ad esempio la presenza di Modi Bloccati nel plasma.

In questo lavoro, le reti neurali Multi Layer Perceptron stimano il rischio di disruzione a partire da un set di segnali diagnostici che definiscono lo stato del plasma.

Sono stati sviluppati due diversi approcci per distinguere plasmi stabili (quindi senza precursori) da plasmi instabili (in cui si presume la presenza dei precursori di disruzione).

Nel primo caso viene sfruttata l'informazione sulla dinamica della disruzione proveniente dalla classe di disruzione.

Nel secondo caso l'informazione proviene dalla clusterizzazione dei segnali in ingresso alla rete MLP, ipotizzando che il sistema abbia una dinamica che varia con continuità nel tempo, e che stati instabili siano vicini nello spazio degli ingressi.

Il sistema di predizione è stato implementato in real-time.

L'ultima parte di questo lavoro è incentrata sull'individuazione di nuovi stati del plasma non presenti nel Training Set. Tali stati, per i quali l'uscita della rete è inaffidabile, possono essere utilizzati per riaddestrare la rete MLP.

Un problema che infatti viene riscontrato in questo tipo di sistema è il cosiddetto 'invecchiamento' della rete. La macchina JET è una macchina sperimentale in cui vengono esplorati ad ogni campagna nuovi spazi operativi della macchina. Ciò produce degli stati del plasma sempre nuovi che la rete MLP non è stata addestrata a riconoscere.

Utilizzando delle tecniche di Novelty Detection [71] [72] [73] è possibile conoscere il grado di 'novità' di un ingresso rispetto al Training Set ed utilizzare questa informazione per valutare l'affidabilità della rete e riaddestrarla quando necessario.

8.1 Database

Il database utilizzato per il sistema di predizione è quello usato per la progettazione del tool di classificazione (vedi Cap.4 per la scelta dei segnali), con alcune differenze.

I segnali utilizzati per addestrare le MLP sono nove:

- | | | |
|-----------------------|------|-----|
| 1. Corrente di plasma | Ipla | [A] |
| 2. Modo bloccato | ML | [T] |

3. Densità del plasma	Dens	[n*m ⁻³]
4. Potenza in ingresso	Ptot	[W]
5. Potenza Irradiata	Prad	[W]
6. Beta poloidale	Betap	[AU]
7. Induttanza interna	Lint	[AU]
8. Posizione verticale del centroide	Posv	[m]
9. Fattore di sicurezza	Q95	[AU]

Rispetto al database precedente è stato eliminato il segnale della derivata dell'energia, che nel lavoro della classificazione ha dimostrato di non essere particolarmente importante.

I segnali selezionati sono tutti di tipo JPF e presenti nel sistema in real-time. Inoltre possono essere opportunamente scalati allo scopo di ottenere dei parametri 'machine independent'.

Poiché i segnali selezionati vengono acquisiti da diversi sistemi, essi presentano dei tempi di campionamento diversi; è quindi necessaria una sincronizzazione dei diversi sistemi di acquisizione, che simuli l'acquisizione dei segnali in real-time, e che abbia un tempo di campionamento sufficientemente breve per poter descrivere completamente la dinamica dei fenomeni presenti nel plasma non solo nella fase disruttiva. Il tempo di campionamento scelto è 20 ms: esso rappresenta il minimo tempo di campionamento fra quelli dei segnali selezionati.

I tempi di campionamento per questi segnali sono molto più brevi (circa 2 ms) ma i dati salvati sono sottocampionati rispetto ai segnali in real-time allo scopo di risparmiare memoria.

Per simulare l'acquisizione dei segnali in real-time, fissato l'istante di campionamento, si considerano i valori dei segnali più vicini fra i successivi.

Gli impulsi selezionati appartengono, come per la classificazione, al range di impulsi 47830-57346, prodotti al JET tra marzo 1999 e Ottobre 2002

I criteri utilizzati per selezionare gli impulsi sono:

- ✓ Corrente di plasma maggiore di 1,5MA;
- ✓ Configurazione in X-point;
- ✓ Profilo di corrente al Flat-Top.

La configurazione in X-point e il profilo di corrente al Flat-Top deve essere mantenuto per un periodo di almeno 800 ms (40 campioni). In Figura 8.1 viene indicato l'intervallo selezionato nel caso dell'impulso 51519; il segnale di X-point indica che si è raggiunta questa configurazione quando il suo valore è uguale a -1 , mentre per valori diversi da -1 il plasma è in configurazione Limiter.

E' stata inoltre verificata la presenza di outlier nel database che ha portato all'esclusione di alcuni impulsi.

In totale si sono selezionati 178 impulsi disrotti; per 92 di questi è nota la classe di disruzione.




Figura 8.1: Intervallo in configurazione X-point selezionato

Sono stati inoltre selezionati 102 impulsi che terminano senza disrompere, a cui ci si riferirà con il nome di ‘impulsi buoni’. Gli impulsi buoni rispondono agli stessi criteri dei disrotti ed appartengono allo stesso range di impulsi, essi sono stati selezionati tra quelli appartenenti allo stesso esperimento degli impulsi disrotti. La Figura 8.2 mostra alcuni segnali dell’impulso 53446 utilizzato per l’addestramento del predittore.




Figura 8.2: Impulso buono

9. APPROCCI ALLA PREDIZIONE E RISULTATI

Il problema della predizione del rischio di disruzione è stato affrontato con due diversi approcci che si differenziano per la scelta del target della rete.

Nel primo approccio impulsi appartenenti a classi diverse sono associati durante l'addestramento ad uscite diverse.

Nel secondo approccio, l'uscita della rete è stabilita sulla base delle indicazioni fornite da una tecnica di clusterizzazione che separa i campioni buoni da quelli contenenti i precursori.

9.1 Approccio basato sulla classe di disruzione

Il database utilizzato per addestrare le reti MLP contiene 92 impulsi di cui è conosciuta la classe di disruzione e 102 impulsi buoni. Per ogni impulso è stata selezionata una sequenza temporale di 40 campioni con un tempo di campionamento pari a 20 ms. Si è optato per non utilizzare l'intero impulso perché questa scelta avrebbe appesantito l'addestramento della rete MLP, utilizzando informazioni ridondanti.

Per ciascun impulso disrotto i 40 campioni selezionati appartengono all'intervallo dell'impulso più prossimo alla disruzione, cioè alla finestra temporale $[t_D-840\text{ ms}, t_D-40\text{ ms}]$ dove t_D è il tempo di disruzione. Sono stati esclusi dall'addestramento gli ultimi 40 ms prima del tempo di disruzione, allo scopo di non considerare le fasi di collasso di temperatura e di corrente in cui le misure sono poco attendibili a causa delle forti correnti indotte.

Per ciascun impulso buono, ipotizzando i campioni equivalenti dal punto di vista del contenuto informativo, sono stati scelti 40 campioni random durante la fase di Flat-Top

9.1.1 Modello neurale

La rete neurale utilizzata è un tradizionale MLP.

Anche in questo caso è stato utilizzato il toolbox Neural Network di Matlab [44] e l'algoritmo di addestramento di Levenberg Marquardt [43].

La rete MLP è costituita da 9 neuroni nello strato di ingresso che corrispondono ai 9 segnali diagnostici selezionati al generico istante t .

Il singolo neurone dello strato di uscita fornisce un numero reale nell'intervallo $[0,1]$ che rappresenta il rischio di disruzione.

Le funzioni di attivazione sono logistiche sigmoidali.

Il target della rete $y(t)$, per ciascun impulso disrotto, è una sigmoide nella finestra temporale di 800 ms, $[t_D-840 \text{ ms}, t_D-40 \text{ ms}]$, il cui valore rappresenta la prossimità di disruzione all'istante t .

$$y(t) = \frac{1}{1 + e^{-[t-(t_D-t_\alpha)]/\tau}} \quad (9.1)$$

dove t_D rappresenta il tempo di disruzione, t è il generico istante di campionamento, τ è il tempo di campionamento e t_α è l'istante di tempo tale che $y(t_\alpha)=0.5$.

Il valore di t_α dipende dalla classe di disruzione. Poiché i precursori della classe DL appaiono in anticipo rispetto a quelli delle altre classi, per questa classe di disruzione si considera una sigmoide più ripida. Infatti:

- ✓ $t_\alpha=320$ ms per gli impulsi appartenenti alla classe Densità Limite;
- ✓ $t_\alpha=280$ ms per gli impulsi appartenenti alle restanti classi di disruzione.

Nella Figura 9.1 vengono riportate le sigmoidi relative al caso di impulsi appartenenti ad una generica classe di disruzione, e alla classe DL.




Figura 9.1: Target della rete per una generica classe di impulsi disrotti e per la classe DL

Gli impulsi sono stati divisi in due set per evitare problemi di overfitting. Il Training Set è composto dal 75% degli impulsi disrotti (2760 campioni) e dal 75% degli impulsi buoni (3080 campioni). Il restante 25% costituisce il Validation Set (920 campioni disrotti e 1000 campioni buoni).

La Tabella 9-1 riporta la ripartizione degli impulsi fra i due set.

	Training Set	Validation Set
Disrotti	69	23
Buoni	77	25

Tabella 9-1: Distribuzioni degli impulsi fra Training Set e Validation Set

I segnali di ingresso sono stati scalati nell'intervallo $[0,1]$.

Per selezionare la migliore architettura neurale sono state effettuate molteplici sessioni di addestramento facendo variare sia il numero degli strati nascosti che il numero di neuroni per ciascuno strato.

Le performance delle reti MLP sono state quantificate in termini di Falsi Allarmi (FA) e Mancati Allarmi (MA).

Per un impulso buono, il sistema predittivo produce un Falso Allarme se il valore massimo della serie temporale prodotta dalla rete MLP supera un dato valore di soglia th .

Per gli impulsi disrotti si considera un Mancato Allarme se nessun campione della serie temporale supera una data soglia th almeno 100 ms prima del tempo di disruzione.

La scelta di fornire un allarme 100 ms prima del tempo di disruzione è legata al tempo di intervento dei sistemi di spegnimento rapido o degli eventuali sistemi di protezione.

Il valore th è il valore che minimizza la funzione di errore:

$$E(th) = w_{FA} \cdot PFA(th) + PMA(th) \quad (9.2)$$

dove $PFA(th)$ è la percentuale dei Falsi Allarmi definita come il numero di Falsi Allarmi diviso il numero totale di impulsi buoni, $PMA(th)$ è la percentuale dei Mancati Allarmi definita come il numero dei Mancati Allarmi diviso il numero totale di impulsi disrotti e w_{FA} è un fattore di peso dei Falsi Allarmi.

L'errore sugli impulsi buoni, cioè il numero di Falsi Allarmi, è stato penalizzato con il fattore di peso $w_{FA} = 4$, perché in una macchina sperimentale come il JET un Falso Allarme comprometterebbe i risultati di un intero esperimento. Al contrario, nei reattori di prossima generazione come ITER, sarà necessario minimizzare il numero di Mancati

Allarmi. Nell'approccio proposto ciò corrisponde a utilizzare un differente fattore di peso.

9.1.2 Risultati

Si sono ottenuti i migliori risultati con una rete composta da:

- 9 neuroni nello strato di ingresso;
- 2 strati nascosti, di rispettivamente 12 e 10 neuroni per strato;
- 1 neurone nello strato di uscita.

Nella Tabella 9-2 è riportato il numero dei Mancati Allarmi e dei Falsi Allarmi per il Training Set e per il Validation Set.

	Training Set	Validation Set
MA	2/69	0/23
FA	1/77	1/25

Tabella 9-2: Performance della rete MLP

I risultati sopra riportati pur essendo soddisfacenti, si riferiscono però ai 40 campioni selezionati per ciascun impulso. Quando alla rete viene presentata l'intera sequenza dell'impulso, il numero dei Falsi Allarmi aumenta in maniera considerevole.

Ciò significa che la rete MLP non è stata addestrata con informazioni sufficienti per riconoscere i diversi tipi di stati buoni. Si rende quindi necessario addestrare la rete MLP con campioni selezionati in una finestra temporale più ampia. Considerare tutti i campioni porterebbe però ad un notevole aumento della dimensionalità del Training Set.

E' necessaria quindi una nuova procedura per selezionare solo i campioni significativi sull'intera sequenza dell'impulso, soprattutto per gli stati buoni del plasma, a cui corrisponde un enorme numero di campioni.

9.2 Approccio basato sul clustering

Per la selezione dei campioni da utilizzare per l'addestramento della rete si è utilizzata una tecnica di clustering.

La procedura di clustering viene effettuata da un Self Organizing Map [57]. Una Self Organizing Map è una rete neurale non supervisionata visualizzabile come una mappa, i cui neuroni di uscita conservano la topologia dello spazio degli ingressi. Nodi vicini nella mappa SOM rappresentano patterns simili, mentre nodi spazialmente lontani nella mappa, lo sono anche nello spazio degli ingressi.

La struttura del sistema di predizione di disruzioni è costituita da un blocco di clustering in cascata con un predittore di tipo neurale.

9.2.1 Il predittore neurale

Per ciascun impulso disrotto è stata addestrata una rete SOM. La rete ha 9 ingressi corrispondenti a ciascuno dei segnali diagnostici. Il Training Set è costituito da tutti i campioni di ogni impulso disrotto esclusi gli ultimi 40 ms prima del tempo di disruzione. Il risultato di questo addestramento è una mappa SOM in cui ogni cluster contiene dati di ingresso simili. In Figura 9.2 la mappa SOM è stata semplificata per metterne in evidenza le caratteristiche più interessanti e renderla di più facile leggibilità.

Per i cluster dei buoni, che nella Figura 9.2 sono evidenziati in celeste, in fase di addestramento si considera solo un campione per ciascun neurone; l'uscita della rete MLP è settata uguale a 0.1.

Questa procedura si basa sull'ipotesi che campioni molto vicini nello spazio degli ingressi abbiano tutti lo stesso contenuto informativo, per cui considerarli tutti in fase di addestramento, non aggiunge informazioni utili ma rende solo più onerosa la fase di addestramento.

I campioni appartenenti a cluster che si trovano fra l'insieme dei campioni buoni, e quello dei disrotti, individuano una 'fascia di incertezza'. I campioni di questa fascia sono stati esclusi dalla fase di addestramento, nell'ipotesi che appartengano agli istanti di transizione fra le fasi dei pre-precursori e quella dei precursori della disruzione.

Nell'esempio in Figura 9.2 i cluster evidenziati in rosa appartengono alla fascia di incertezza.

Con questa procedura la quantità di campioni per ogni impulso da utilizzare per la fase di addestramento è stata ridotta in maniera considerevole senza però perdere utili informazioni. Infatti 86 impulsi disrotti composti da un totale di 36316 campioni, sono rappresentati efficacemente da 7070 campioni selezionati con la procedura di clustering ora descritta.

Di contro è stato necessario escludere sei impulsi in cui la mappa SOM non presentava una chiara distinzione tra cluster disrotti e cluster buoni.

Nella Figura 9.3 è riportata la mappa SOM dell'impulso 51515, in cui non è stato possibile individuare il cluster dei disrotti, cioè quello a cui appartiene il campione numero 75. Infatti nella mappa non è possibile seguire la normale dinamica della disruzione, in quanto campioni vicini nel tempo non lo sono nella mappa.

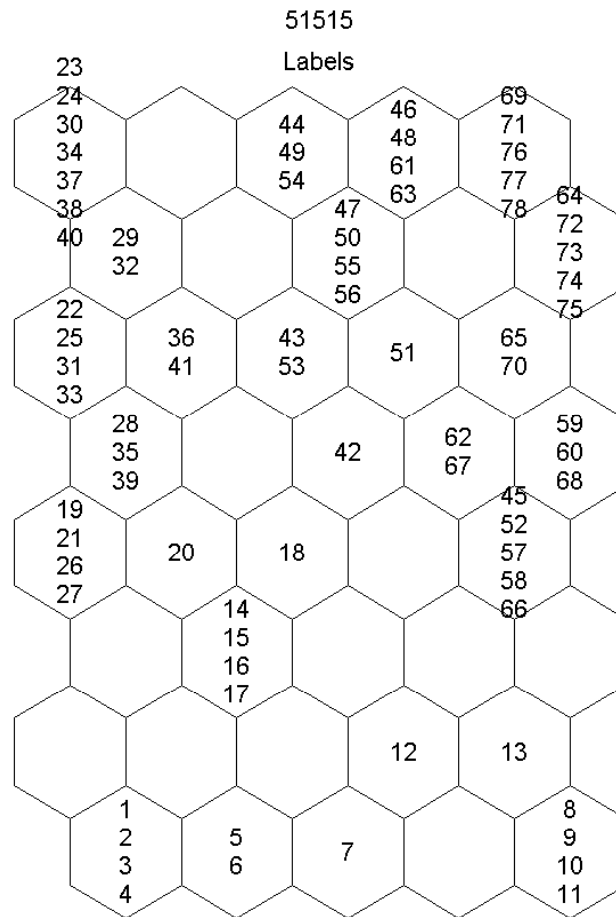


Figura 9.3: Som dell'impulso 51515

La rete MLP ha 9 ingressi per ciascun campione selezionato dalla SOM. Le funzioni di attivazione sono logistiche sigmoidali.

Il Training Set è composto da 69 impulsi disrotti (5722 campioni), il Validation Set è composto da 17 impulsi disrotti (1348 campioni).

Il Test Set è composto da 86 impulsi disrotti (34407 campioni) e 102 impulsi buoni (61185 campioni). Questi dati sono riassunti in Tabella 9-3.

Un' importante caratteristica di questo database è che gli impulsi buoni non vengono utilizzati in fase di addestramento ma solo di test.

Infatti si ipotizza che tutta l'informazione sullo stato buono possa essere estrapolata semplicemente dalla parte considerata buona di un impulso disrotto.

	Training Set	Validation Set	Test Set
Impulsi disrotti	69	17	86
Campioni disrotti	5722	1348	34407
Impulsi buoni			102
Campioni buoni			61185

Tabella 9-3: Distribuzione degli impulsi nel Training Set, Validation Set e Test set

Il sistema diagnostico produce un Falso Allarme se durante un impulso buono due uscite consecutive del sistema predittivo superano una determinata soglia, oppure se durante un impulso disrotto il superamento della soglia per due uscite consecutive avviene più di un secondo prima rispetto al tempo di disruzione.

Viene invece considerato Mancato Allarme il caso in cui per un impulso disrotto la soglia non viene superata da almeno due uscite consecutive negli istanti che precedono la disruzione di almeno 100 ms.

La scelta del valore di soglia è descritta nel Par. 9.1.1.

9.2.2 Risultati

La miglior configurazione neurale è composta da:

- 9 neuroni nello strato di ingresso;
- 15 neuroni nello strato nascosto;
- 1 neurone nello strato di uscita.

La rete è composta da 166 parametri.

In Tabella 9-4 sono riportati gli errori della rete MLP divisi in Falsi e Mancati Allarmi per il Training, Validation e Test Set. L'errore sul Training Set è calcolato utilizzando l'intera sequenza dell'impulso, non solo la parte selezionata con le SOM utilizzata durante l'addestramento.

	Training Set	Validation Set	Test Set
MA	0/69	3/17	28/86
FA	3/69	0/17	11/188

Tabella 9-4: Performance del migliore MLP

Come si può notare, la rete presenta delle buone prestazioni in termini di Falsi Allarmi, dimostrando che utilizzare un solo campione per ciascun neurone delle mappe SOM è sufficiente per descrivere completamente anche quelli non compresi nel Training Set.

Nella Figura 9.4 viene riportata l'uscita della rete per l'impulso 51519 appartenente al Training Set. Come si può notare, la rete riconosce tutti i campioni buoni. Inoltre per quel che riguarda i campioni incerti, nel disegno compresi tra le due righe verticali, l'uscita della rete rispecchia perfettamente la dinamica del plasma che si porta con continuità da uno stato buono (uscita 0.1) ad uno stato disrotto (uscita 0.9).

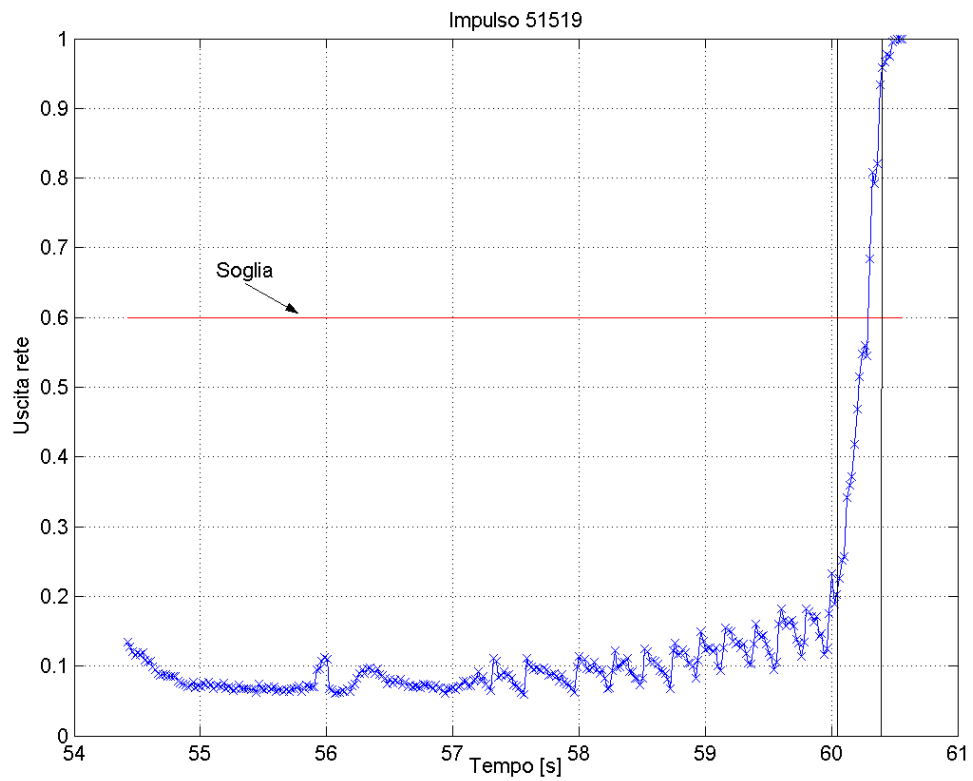


Figura 9.4: Uscita della rete MLP per l'Impulso 51519

Nella Figura9.5 è possibile identificare lo stesso comportamento della rete per un impulso di Test.




Figura 9.5: Uscita della rete MLP per l'Impulso 54209

La rete presenta una percentuale piuttosto alta di Mancati Allarmi sul Test Set. Ciò può essere dovuto al fatto che circa 40 impulsi appartenenti al Test Set sono molto vecchi (circa 15 mesi) rispetto agli impulsi del Training Set. Inoltre alcuni di essi presentano particolari configurazioni (elmy h-mode) non presenti nel Training Set.

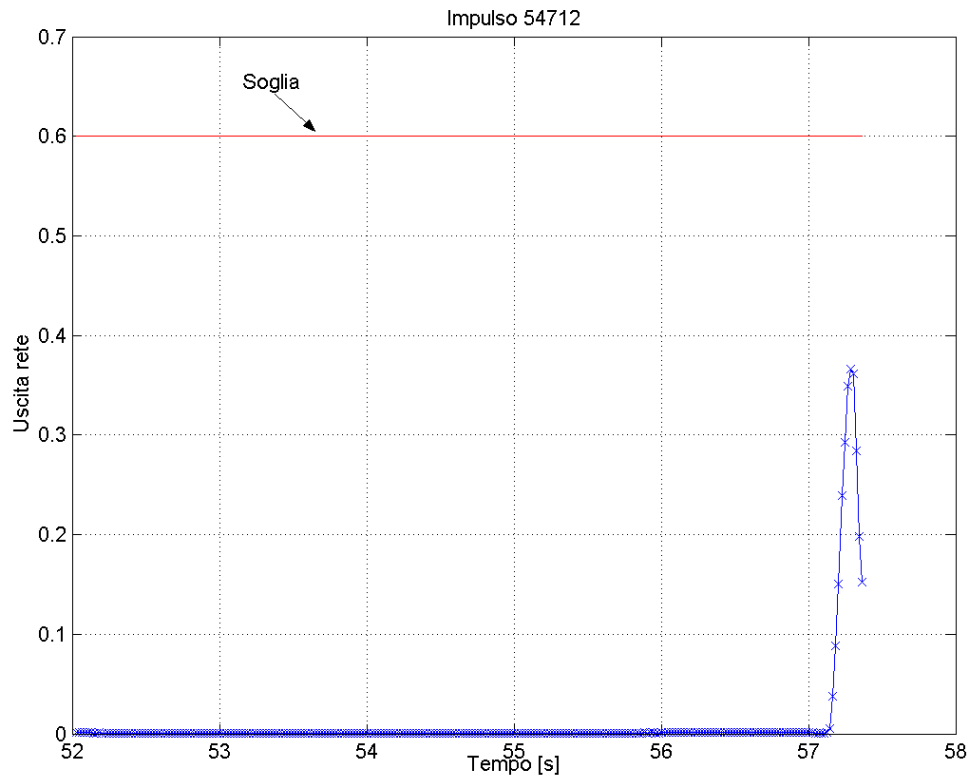


Figura 9.6: Uscita della rete per l'Impulso 54712

In conclusione, il sistema di predizione composto dal blocco di clustering e da quello di predizione ha permesso di ridurre in maniera significativa le dimensioni del Training Set senza perdita di utili informazioni contenute negli interi impulsi.

Grazie alla presenza di queste informazioni in fase di addestramento è stato perciò possibile ridurre il numero dei Falsi allarmi, principale limite del precedente approccio.

9.2.3 Confronto sistema di predizione-Soft Stop

Per analizzare le capacità di predizione del sistema realizzato, le prestazioni della rete MLP sono state confrontate con di quelle del Soft Stop.

Il Soft Stop è una procedura di spegnimento rapido, azionata dall'indicatore di Mode Lock, che è al momento l'unico sistema di protezione da disruzioni implementato on-line al Jet.

In Tabella 9.5 sono riportate le percentuale di Mancati Allarmi per la rete MLP e per il Soft Stop.

	MLP	SS
<i>MA</i>	28/86 (32%)	44/86 (51%)

Tabella 9-5: Confronto fra MLP e SS

Di questi Mancati Allarmi 21 sono in comune fra i due sistemi.

Inoltre, confrontando il tempo di predizione di quegli impulsi correttamente predetti da entrambi i sistemi, nel 64% delle volte la rete MLP predice in anticipo rispetto al Mode Lock.

9.3 Implementazione on-line

Il sistema di predizione è stato implementato in real-time.

Il programma, scritto in linguaggio C++:

- ✓ Acquisisce i segnali dalla rete real-time.
- ✓ Calcola l'uscita con i parametri della rete MLP pre-impostati.
- ✓ Scrive i risultati in un file JPF.

Il sistema è al momento in fase di test.

10. NOVELTY DETECTION

Le performance di una rete neurale addestrata su un certo Training Set sono destinate inevitabilmente a deteriorarsi nel tempo. Infatti una rete neurale addestrata a discriminare fra ingressi che presentano una certa distribuzione, sarà ‘confusa’ quando gli ingressi presenteranno una distribuzione completamente differente. Questo è il caso di macchine sperimentali come il JET, dove nuove configurazioni di plasma possono portare a stati del plasma stesso completamente nuovi rispetto a quelli presenti nel Training Set.

Un miglioramento può essere apportato utilizzando tecniche di *Novelty Detection* [71] che forniscono utili informazioni sull’attendibilità dell’uscita della rete sulla base del grado di novità dell’ingresso presentatole. Recentemente, sono stati proposti in letteratura diversi metodi di Novelty Detection [71] [72] [73].

In questo capitolo sono presentati i risultati preliminari di una tecnica di Novelty Detection applicata al sistema di predizione di disruzioni installato al JET.

Il sistema di predizione è composto da tre blocchi mutuamente connessi, Figura 10.1.

Durante la fase di addestramento, una Self Organizing Map seleziona i campioni da utilizzare per addestrare il Multi Layer Perceptron a predire le disruzioni. Durante l’applicazione on-line, il sistema di Novelty Detection calcola l’affidabilità dell’uscita della rete, e i campioni che presentano un basso valore di affidabilità sono eliminati o almeno etichettati come sospetti. In una seconda fase saranno utilizzati per aggiornare il sistema di predizione.

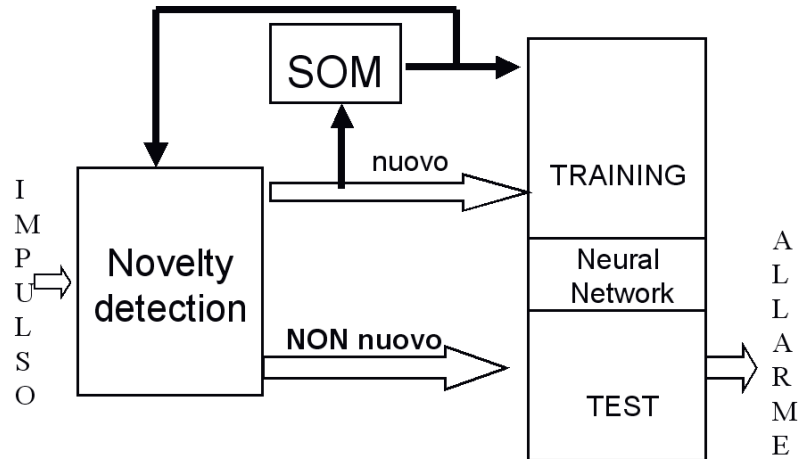


Figura 10.1: Schema del sistema di predizione

10.1 Tecniche di Novelty Detection

Per tecniche di Novelty Detection si intendono tecniche in grado di identificare dati o segnali nuovi o sconosciuti rispetto ad un Training Set utilizzato per addestrare una macchina ad apprendimento, come una rete neurale.

La Novelty Detection è fondamentale per interpretare in maniera appropriata i risultati di un sistema di classificazione o di identificazione, giacché, soprattutto in sistemi che evolvono nel tempo, è possibile che informazioni necessarie per un corretto utilizzo non siano disponibili durante la fase di addestramento.

Queste tecniche per l'identificazione di 'situazioni nuove' hanno trovato applicazione in molti campi come l'identificazione di guasto, identificazione del target del radar, il controllo statistico di processi e molti altri.

Gli approcci alla Novelty Detection possono essere divisi in due grandi classi:

- ✓ Approcci statistici;
- ✓ Approcci neurali.

Gli approcci statistici [72], sono basati sulla modellizzazione dei dati che rappresenti le proprietà statistiche del Training Set. Successivamente si verifica se il campione di Test appartiene al modello. Le tecniche basate su questo principio variano a seconda della loro complessità. L'approccio più semplice è quello di costruire la funzione densità dai dati a disposizione (Training Set), e calcolare la probabilità che un campione nuovo appartenga a quella funzione di densità. Il valore della probabilità dà un'indicazione della novità di un campione.

L'approccio neurale è stato largamente applicato nell'ambito della Novelty Detection [73]. Le reti neurali hanno infatti il vantaggio che non necessitano di nessuna assunzione a priori sulla distribuzione dei dati. Sono state studiate diverse architetture come Multi Layer Perceptron, Self Organizing Maps, reti Radial basis function, Support Vector machines, Reti di Hopfield etc.. Nell'ambito della Novelty Detection alcuni tipi di rete neurale sono più adatti di altri. La mancanza di sufficienti studi comparativi di analisi delle prestazioni di Novelty Detection e la sua relazione tra il tipo e la qualità dei dati usati, rende però assai difficile dare un giudizio oggettivo che non sia solamente un riassunto degli studi in questo ambito [73].

10.2 Risultati preliminari

La progettazione di un sistema per la Novelty Detection è composta di due fasi.

In una prima fase si realizza un modello del Training Set e in una seconda fase si definisce la soglia oltre la quale il campione viene considerato non appartenente alla distribuzione del Training Set.

In questo studio si è modellato il Training Set per mezzo di una Self Organizing Map. La mappa risultante è costituita da 26×16 neuroni, per un totale di 416 neuroni.

E' stata definita una soglia diversa per ciascun neurone, pari al valore massimo dell'errore di quantizzazione commesso in quel neurone.

Quando la rete SOM viene usata come Novelty Detector, si individua la Best Matching Unit relativa al campione da analizzare, si calcola l'errore di quantizzazione del campione e se questo è superiore alla soglia precedentemente definita per quel neurone, il campione è etichettato come 'nuovo'.

Il Novelty Detector così progettato è stato testato in congiunzione con la migliore rete neurale MLP. Poiché il sistema elabora un campione alla volta, si è verificata la risposta del Novelty Detector in corrispondenza di quei campioni in cui la rete MLP dava l'allarme (uscita superiore alla soglia), oppure l'avrebbe dovuto dare.

Su 10 Falsi Allarmi dati dalla rete MLP, 8 di questi sono stati invalidati dal Novelty Detector, infatti sono stati etichettati come nuovi, e quindi nell' utilizzo on-line avrebbero inibito l'allarme del predittore.

Su 23 Mancati Allarmi, 13 sono stati etichettati come nuovi, quindi da utilizzare in fase di aggiornamento della rete MLP.

Per 23 impulsi disrotti in cui la rete MLP ha correttamente dato l'allarme, questo sarebbe stato inibito dal Novelty Detector, facendo aumentare considerevolmente i Mancati Allarmi del sistema predittivo.

Questa implementazione del Novelty Detector si è rivelata troppo prudente; ha infatti etichettato come nuovi più della metà dei campioni.

E' importante però notare che, con la tecnica proposta, il Test Set risulta 'nuovo' rispetto al Training Set.

11. PREDIZIONE DI DISRUZIONI - CONCLUSIONI

Scopo di questa seconda parte della tesi è stato l'applicazione di tecniche neurali alla predizione di disruzioni, volto alla implementazione on-line del sistema di predizione. Il blocco predittore è stato realizzato con una rete neurale di tipo Multi Layer Perceptron.

L'addestramento della rete è stato effettuato secondo due modalità. Nel primo approccio è stata sfruttata la conoscenza della classe di disruzione associata ad ogni impulso disrotto: durante l'addestramento, impulsi appartenenti a classi diverse sono stati caratterizzati con uscite diverse. La rete è stata addestrata considerando 40 campioni per ogni impulso.

I risultati ottenuti hanno evidenziato che gli stati disrotti presentano in generale una varietà limitata, mentre gli stati buoni presentano caratteristiche molto diverse gli uni dagli altri. Infatti, la rete testata sull'intero impulso classifica erroneamente molti campioni buoni interpretandoli come disrotti, presentando un numero di Falsi Allarmi che sarebbe inaccettabile per un sistema on-line.

Si è reso quindi necessario addestrare la rete incrementando l'informazione fornita sugli stati buoni. Nel secondo approccio, il blocco predittore Multi Layer Perceptron è in cascata ad una Self Organising Map. La mappa risultante dalla Self Organising Map raggruppa, per ogni impulso disrotto, campioni simili nello stesso cluster attraverso un'analisi basata sulle distanze euclidee dei campioni nello spazio degli ingressi.

Tale informazione permette di ridurre la dimensione del Training Set senza perdere informazioni necessarie alla definizione degli stati del plasma. Fornisce inoltre cruciali informazioni sulla transizione fra stato buono e stato disrotto, corrispondente al passaggio del plasma dalla fase dei pre-precursori a quella dei precursori, a meno di una fascia di incertezza. La fascia di incertezza contiene i campioni dei cluster che non sono

classificabili con certezza come buoni o come disrotti. Essi non sono considerati in fase di addestramento poiché potrebbero introdurre ambiguità nel modello.

La procedura descritta ha consentito di migliorare significativamente i risultati del predittore.

Il sistema di predizione è ora implementato in real-time al JET.

L'inevitabile invecchiamento del sistema di predizione è un problema sentito particolarmente in macchine sperimentali come il JET, in cui l'esplorazione degli spazi operativi della macchina porta a nuovi e sconosciuti stati del plasma. E' quindi necessario un sistema per identificare l'affidabilità dell'uscita del predittore ed effettuare l'aggiornamento in linea della rete stessa.

Seppure i risultati siano solo preliminari, le tecniche di Novelty Detection hanno dimostrato di essere le più adatte per questo tipo di problema. Infatti esse permettono di associare all'uscita del sistema di predizione un grado di affidabilità, indice della 'novità' di un campione.

Il problema dei fenomeni distruttivi nei plasmi dei TOKAMAK e i loro effetti disastrosi sulla macchina non può essere ancora considerato risolto con un sistema di protezione del tipo presentato in questa tesi. Ulteriori studi dovranno chiarire completamente la fisica che sta alla base del fenomeno distruttivo, per permettere un controllo di questo fenomeno.

12. CONCLUSIONI GENERALI

Il fenomeno delle disruzioni nei TOKAMAK costituisce un'importante campo di studio nell'ambito della fusione nucleare, in quanto pone forti limiti allo sviluppo di questa tecnologia. Ancora oggi la fisica alla base delle disruzioni non è completamente compresa. Alla base vi sono complessi fenomeni che dipendono dalla causa o dall'insieme di cause che ha condotto alla disruzione.

Esistono in letteratura numerosi risultati sperimentali che, pur fornendo un valido contributo alla comprensione del fenomeno, non forniscono le basi teoriche sufficienti per lo sviluppo di un modello matematico.

In questa tesi sono state applicate e integrate alcune tecniche di soft computing per risolvere due aspetti legati al fenomeno disruttivo: la classificazione del tipo di disruzione e la predizione delle disruzioni. In particolare, le reti neurali si sono rivelate un valido strumento per la soluzione di entrambi i problemi.

Il database e le informazioni necessarie allo studio derivano dagli esperimenti condotti nel TOKAMAK JET di Culham.

Il sistema di classificazione fornisce in pochi millisecondi l'informazione sulla causa che ha condotto alla disruzione un dato impulso.

Il tool è attualmente implementato al JET; esso è di facile utilizzo e rende accessibile anche a utenti non esperti un'importante informazione che altrimenti necessiterebbe di un'analisi visiva dei segnali diagnostici effettuabile solo da esperti del settore.

Il sistema di predizione consente di aumentare la sicurezza durante un esperimento e preservare l'integrità del reattore. Esso fornisce un allarme almeno 100ms prima della disruzione.

Il tool è attualmente implementato al JET in modalità on-line ed è in fase di test. Esso dovrà essere integrato con un blocco 'Novelty Detector', ancora in fase di progetto, necessario per un utilizzo on-line del sistema.

Si rimanda al Cap. 7 per le conclusioni specifiche sul sistema di classificazione ed al Cap. 11 per le conclusioni sul sistema di predizione.

BIBLIOGRAFIA

- [1] **ONGENA J. AND VAN OOST G.**, “*Energy for future centuries*”, Transactions of Fusion Technology, **37**, 3, 2000
- [2] **TAMM I AND SAKHAROV A.**, “*Plasma physics and the problem of controlled thermonuclear reactions* ”, Edt. M.A. Leontovich, Pergamon Press, Vol.1, 1961
- [3] **WESSON J.**, “*Tokamaks -Third edition* ”, Oxford University Press, 2004
- [4] **DENDY R.**, “*Plasma physics: an introductory course* ”, Cambridge University Press, 1993
- [5] **WESSON J.A. ET AL**, “*Disruptions in JET*”, Nuclear Fusion, **29**, 641, 1989
- [6] **NAVE M.F.F. AND WESSON J.A.**, “*Mode Locking in Tokamaks*”, Nuclear Fusion, **vol.30**, 2575, 1990
- [7] **GORBUNOV E.P. RAZUMOVA K.A.**, “*Effect of a strong magnetic field on the magnetohydrodynamic stability of the plasma and the confinement of charged particles in the tokamak machine*”, Atomnaya Energaya, **15**, 363, 1963
- [8] **MURAKAMI M., CALLEN J.D., BERRY L.A.**, “*Some observation on maximum Density in Tokamaks Experiments*”, Nuclear Fusion, **16**, 347, 1976
- [9] **FIELDING S.J., HUGILL J, MCCRACKEN G.M., PAUL J.W.M., PRETINCE R., STOTT P.E.**, “*High-Density discharges with gettered Torus walls in DITE*”, Nuclear Fusion, **17**, 1382,1977
- [10] **GREENWALD M. ET AL.**, “*A new look at Density Limit in Tokamaks*”,

-
- Nuclear Fusion, **28**, 2199, 1988
- [11] **GREENWALD M.**, “*Density limits in toroidal plasmas*”, Plasma Physics and Control Fusion, **44**, R27, 2002
- [12] **NOLL P. ET AL.**, “*Stabilization of vertical position and control of plasma shape in JET*”, Proc. 11th Symposium on Fusion Engineering, Texas, **vol I**, 33, 1985
- [13] **LAO L.L., AND JENSEN T.H.**, “*Magnetohydrodynamic equilibria of attached plasma after loss of vertical stability in elongated plasma*”, Nuclear Fusion, **31**, 191, 1990
- [14] **SCHULLER F.C.**, “*Disruptions in Tokamak*”, Plasma Physics and Control Fusion, **37**, R135, 1995
- [15] **WESSON J.A. AND SYKES A.**, “*Tokamaks β limit*”, Nuclear Fusion, **25**, 85, 1985
- [16] **STRAIT E.J.**, “*Stability of high beta Tokamak plasmas*”, Physics of plasmas, **1**, 1415, 1994
- [17] **ITER PHYSICS EXPERT GROUP ON DISRUPTION ET AL.**, “*Chapter 3 : MHD stability, operational limits and disruptions*”, Nuclear Fusion, **39**, 2251, 1999
- [18] **SCOVILLE J.T. ET AL.**, “*Locked modes in DIII-D and a method for prevention of the low density mode*”, Nuclear Fusion, **31**, 875, 1991
- [19] **FITZPATRICK R.**, “*Interaction of tearing modes with external structures in cylindrical geometry*”, Nuclear Fusion, **33**, 1049, 1993
- [20] **OHYABU N.**, “*Density limit in Tokamak*”, Nuclear Fusion, **9**, 1491, 1979
- [21] **PAUTASSO G. ET AL.**, “*Causes, precursor and mechanisms of disruptions*”

-
- in ASDEX Upgrade*”, ICPP&25th EPS Conf. on Control Fusion and Plasma Physics (Praha, 29 June-3 July), **22C**, 520, 1998
- [22] **ZEDDA M.K., BOLZONELLA T., CANNAS B., FANNI A., HOWELL D., JOHNSON M.F., SONATO P. AND JET EFDA CONTRIBUTORS**, “*Disruption classification at JET with neural techniques*”, 30th EPS Conference on Contr. Fusion and Plasma Phys. (St. Petersburg, 7-11 July), **27A**, 2.93, 2003.
- [23] **VERSACI M., GRECO A., MORABITO F.C.**, “*Multi-Support Vector Machines for Disruption Classssification in TOKAMAK Reactors*”, 23rd Symposium on Fusion Technology (Venice, 20-24September), P2C-D-506, 2004
- [24] **WROBLEWSKI D., JAHNS L., LEUER. J.A.**, “*Tokamak disruption alarm based on neural network model of high-beta limit*”, Nuclear Fusion, **37**, 725, 1997
- [25] **HERNANDEZ J.V., VANNUCCI A., TAJIMA T., LIN Z. HORTON W., MCCOOL S.C.**, “*Neural Network prediction of some classes of Tokamak disruption*”, Nuclear Fusion, **36**, 1009, 1996
- [26] **VANNUCCI A., OLIVEIRA K.A., TAJIMA T.**, “*Forecast of TEXT plasma disruptions using soft X rays as input signal in neural network*”, Nuclear Fusion, **39**, 255, 1999
- [27] **SEGUNPTA A., RANJAN P.**, “*Forecasting of disruptions in the ADITYA tokamak using neural network*”, Nuclear Fusion, **40**, 1993, 2000
- [28] **MORABITO F.C., VERSACI M., PAUTASSO G., TICHMANN C., THE ASDEX UNPGRADE TEAM.**, “*Fuzzy-Neural approaches to the Prediction of Disruptions in Asdex-Upgrade*”, Nuclear Fusion, **40**, 1715, 2000

-
- [29] **MORABITO F.C., VERSACI M.**, “*Fuzzy Time series approach for Disruptions Prediction in Tokamak Reactors*”, IEEE Transactions on Magnetics, **39**, 1503, 2003
- [30] **SVENSSON J.**, “*Artificial neural network modelling in nuclear fusion research and engineering at the JET Tokamak*”, Ph.D. Dissertation, Royal Institute of technology, Stockholm, 2000
- [31] **MILANI F.**, “*Disruption prediction at JET*”, Ph.D. Dissertation, University of Aston in Birmingham, 1998
- [32] **MARONGIU E.**, “*Neural Network Applications in Tokamaks* ”, Ph.D. Dissertation, University of Cagliari, 2002
- [33] **PAUTASSO G., TICHMANN C., EGOROV S., ZEHETBAUER T., GRUBER O., MARASCHEK M., MAST F., MERTENS V., PERCHERMEIER I., RAUPP G., TREUTTERER W., WINDSOR C., THE ASDEX UNPGRADE TEAM.**, “*On-line prediction and mitigation of disruptions in ASDEX Upgrade*”, Nuclear Fusion, **42**, 100, 2002
- [34] **YOSHINO R.**, “*Neural-net disruption predictor in JT-60U*”, Nuclear Fusion, **43**, 1171, 2003
- [35] **CANNAS B., FANNI A., MARONGIU E., SONATO P.**, “*Disruption forecasting at JET using neural networks*”, Nuclear Fusion, **44**, 68, 2004
- [36] **CANNAS B., FANNI A., SONATO P., ZEDDA M.K.**, “*Progress in disruption prediction at JET using neural networks*”, PIERS Progress in Electromagnetics research symposium (Pisa, 28-31 March), 2004
- [37] **CANNAS B., FANNI A., SIAS G., SONATO P., ZEDDA M.K., AND JET EFDA CONTRIBUTORS.**, “*Neural approaches to disruption prediction at JET*”, 31th EPS Conference on Contr. Fusion and Plasma Phys. (London, 28

-
- June-2 July), **Vol.28G**, p-1.167, 2004.
- [38] **SALZEDAS F.**, *“The Disruptive Instability In Tokamak Plasma”*, Ph.D. Dissertation, University of Utrecht, 2000
- [39] **HAYKIN S.**, *“Neural Networks”*, Wiley & Sons, 2000
- [40] **DUDA R.O., HART P.E. STORK D.G.**, *“Pattern classification”*, Prentice-Hall, 1999
- [41] **PRINCIPE J.C., EULIANO N.R. AND CURT LEFEBVRE W.**, *“Neural and Adaptive Systems”*, Wiley & Sons, 2000
- [42] **BISHOP C.M.**, *“Neural Networks for Pattern Recognition”*, Clarendon Press Oxford, 1995
- [43] **HAGAN M.T., MENHAJ M.**, *“Training a feed-forward neural networks with the Marquardt algorithm”*, IEEE Transactions on Neural Networks, **5**, 989, 1994
- [44] **THE MATHWORKS**, *“Neural Networks Toolbox for use with Matlab, v.6”*, 2001
- [45] **SMITH M.**, *“Neural Networks for Statistical Modeling”*, Van Nostrand Reinhold, New York, 1993
- [46] **HINTON G.E.**, *“Connectionist learning procedures”*, Artificial Intelligence, **4**, 185, 1989
- [47] **WHITE H.**, *“Learning in artificial Neural Networks”*, Neural Computation, **1**, 425, 1989
- [48] **RICHARD M.D. LIPPMANN R.P.**, *“Neural Networks classifiers estimate Bayesian a posteriori probabilities”*, Neural Computation, **3**, 461, 1991
- [49] **CYBENCO G.**, *“Approximation by superposition of a sigmoidal function”*,

-
- Mathematics of Control, Signal and Systems, **2**, 304, 1989
- [50] **SCARSELLI F, TSOI A.C.**, “*Universal approximation using feed-forward neural network: a survey of some existing methods, and some new results*”, Neural Networks, **11**, 15, 1998
- [51] **VAPNIK V.**, “*The nature of Statistical Learning Theory*”, Springer, New York, 1995
- [52] **VAPNIK V.**, “*Principles of risk minimization for learning theory*”, Advances in Neural Information Processing Systems, **4**, 831, 1992
- [53] **CORTES C. VAPNIK V.**, ‘*Support-vector networks*’ Machine Learning, **20**, 273, 1995.
- [54] **BURGES C.J.C.**, “*A Tutorial on Support Vector Machines for Pattern Recognition*”, Data Mining and Knowledge Discovery, **2(2)**, 1, 1998
- [55] **GUNN. S. R.**, ‘*Support Vector Machines for Classification and Regression*’, Technical Report, Image Speech and Intelligent Systems Research Group, University of Southampton, 1997.
- [56] **CRISTIANINI N. SHAWE-TAYLOR J.**, “*Support Vector Machines and Other Kernel Based Learning Methods*”, Cambridge University Press, 2000
- [57] **KOHONEN T.**, “*Self-Organized Formation of Topologically Correct Feature Map*”, Biological Cybernetics, **43**, 59, 1982
- [58] **KOHONEN T.**, “*Self Organizing Maps*”, Proceeding of IEEE, **78 (9)**, 1464, 1990
- [59] **KOHONEN T.**, “*Self Organizing Maps, Third edition*”, Springer-Verlag, Berlin, 2001
- [60] **WINDSOR C.G., PAUTASSO G., TICHMANN C., BUTTERY R.J., HENDER T.C. JET EFDA CONTRIBUTORS AND THE ASDEX**

- TEAM**, “A cross-tokamak neural network disruption predictor”, Nuclear Fusion, submitted
- [61] **ABRAHART R.J., KNEALE P.E.**, “Investigating the role of saliency analysis with a neural network rainfall-runoff model”, Computers & Geosciences , **28-8**, 921, 2001
- [62] **CHANG C.C., LIN C.J.**, “LIBSVM a library for support vector machines”, Software: <http://www.csie.ntu.edu.tw/~cjlin/libsvm>, 2001
- [63] **VESANTO J., HIMBERG J., ALHONIEMI E., PARHANKANGAS J.**, “Self-Organizing Map in Matlab: the som toolbox”, Proceeding of the Matlab DSP Conference 1999, Espoo, Finland, 35, 1999
- [64] Software: <http://www.cis.hut.fi/projects/somtoolbox/>
- [65] **AHANSEN L.K., SALAMON P.**, “Neural Network ensembles”, IEEE transactions on pattern analysis and machine intelligence, **12**, 993, 1990
- [66] **TUMER K., GHOSH J.**, “Linear and Order Statistics Combiners for Pattern Classification, in Combining Artificial Neural Networks”, Springer-Verlag, 127, 1999
- [67] **LAM L., SUEN C.Y.**, “Application of Majority Voting to Pattern Recognition: An Analysis of Its Behaviour and Performance”, IEEE Trans. On Systems, Man and Cynernetics, **Part A27**, 553, 1997
- [68] **TUMER K., GHOSH J.**, “Analysis of Decision Boundaries in Linearly Combined Neural Classifiers”, Pattern Recognition, **29**, 341, 1996
- [69] **XU L., KRZYZAK A., SUEN C.Y.**, “Methods of Combining Multiple Classifiers and Their Applications to Handwritten Numerals”, IEEE Trans. On Systems, Man and Cynernetics, **22**, 418, 1992
- [70] **HUANG Y.S., SUEN C.Y.**, “A Method of Combining Multiple Experts for

- the Recognition of Unconstrained Handwritten Recognition*”, IEEE Trans. On Pattern Analysis and Machine Intelligence , **17**, 90, 1995
- [71] **BISHOP C.M.**, “ *Novelty detection and neural network validation* ”, Proceedings of the IEE Conf. on Vision and Image Processing, 217, 1994
- [72] **MARKOU M., SINGH SAMEER**, “ *Novelty detection: a review- part 1: statistical approaches* ”, Signal Processing, **83**, 2481, 2003
- [73] **MARKOU M., SINGH SAMEER**, “ *Novelty detection: a review- part 2: neural network based approaches* ”, Signal Processing, **83**, 2499, 2003