

Università degli Studi di Padova
Dipartimento di Scienze Statistiche
Corso di Laurea Triennale in
Statistica per le Tecnologie e le Scienze



Relazione finale
**Intelligenza artificiale e deep learning per l'analisi delle prestazioni
sportive**

Relatore Prof. Carlo Ferrari
Dipartimento di Ingegneria dell'Informazione

Laureando : Nicola Bazzani
Matricola N 2003664

Anno Accademico 2023-2024

Indice

1	Introduzione	1
1.1	Introduzione-Abstract	1
1.2	Contesto generale dell'analisi delle prestazioni sportive	2
1.3	L'evoluzione dei Big Data nello sport	2
1.4	Rischi e Limiti	4
1.4.1	Overfitting	4
1.4.2	Black Box (mancanza di interpretabilità)	4
1.4.3	Problemi di generalizzazione	5
1.4.4	Qualità dei dati e questioni etiche	5
2	Metodologie di Raccolta Dati tramite IA	7
2.1	Problemi e Rischi durante la Raccolta Dati	7
2.2	Analisi Notazionale	8
2.2.1	Principi dell'analisi	8
2.2.2	Validità e Affidabilità dell'Analisi Notazionale	9
2.3	Tracciamento Automatico 2D e 3D, e Sensori	10
2.3.1	Sistemi Multi-Videocamera	11
2.3.2	TV Broadcast Tracking	12
2.3.3	Sistemi Optocinetici e Sensori	13
2.4	Variabili Ecologico-Fisiche per Catturare le Dinamiche Ambientali nella Prestazione Sportiva	15
2.4.1	Descrizione e Importanza	15
2.4.2	Esempi di utilizzo	15

3	Applicazioni dell'Intelligenza Artificiale nelle Scienze dello Sport	17
3.1	Metriche individuali	18
3.1.1	Misure Cinematiche	18
3.1.2	Metriche Fisiologiche	21
3.2	Metriche di Gruppo	24
3.2.1	Metriche Spazio-Temporali	24
3.3	Network Metrics	26
4	Intelligenza artificiale per il riconoscimento di azioni e schemi nello sport	31
4.1	Classificazione non-Sequenziale	31
4.1.1	Support Vector Machine	32
4.1.2	Reti Neurali Artificiali	33
4.2	Classificazione Sequenziale	36
4.2.1	Ensemble Learning	37
4.3	Recurrent Neural Networks (RNN) e LSTM	40
4.3.1	Long Short-Term Memory (LSTM)	41
4.4	Esempio con confronto DBMM e LSTM	43
5	Previsione delle Azioni e dei Profili delle Prestazioni	47
5.1	Analisi di Convergenza	48
5.2	Prevedere il Numero di Gol Tentati e Gol Segnati	51
6	Sviluppi futuri dell'IA	55
	Bibliografia	58

Elenco delle figure

3.1	Esempio di rappresentazione grafica di una rete di passaggi tra giocatori. Grafico realizzato con la funzione <i>ggraph</i> dell'omonimo pacchetto	27
4.1	(Sopra) esempio di RNN vanishing problem, (sotto) esempio di conservazione dell'informazione con LSTM[51]	41
4.2	Tabella di errata classificazione: (sopra) DBMM, (sotto) LSTM[51]	45
5.1	Analisi di convergenza di BDMM[51]	49
5.2	Analisi di convergenza di LSTM[51]	49
5.3	Gol tentati[51]	53
5.4	Gol segnati[51]	54

Capitolo 1

Introduzione

1.1 Introduzione-Abstract

In questa tesi si vuole esplorare la bibliografia presente di come l'intelligenza artificiale (IA) possa essere applicata all'analisi delle prestazioni sportive, evidenziandone i principali metodi e benefici. Verrà affrontato l'utilizzo dell'IA nella gestione e interpretazione dei big data, una risorsa sempre più cruciale per migliorare le prestazioni atletiche e ottimizzare i processi di allenamento.

Verranno descritte tecniche innovative per la raccolta e l'elaborazione dei dati, come l'analisi notazionale e i sistemi di tracciamento automatico in due e tre dimensioni, analizzando le variabili fisiche ed ecologiche rilevanti per comprendere le dinamiche di prestazione degli atleti. Successivamente, si esamineranno le applicazioni dell'IA nelle scienze sportive, con particolare attenzione a previsioni di performance, prevenzione degli infortuni e riconoscimento di schemi, tramite metriche individuali e di gruppo.

Una parte sarà riservata al riconoscimento di azioni e schemi di gioco tramite algoritmi di classificazione e previsione, come Support Vector Machine (SVM) e Reti Neurali Ricorrenti (RNN), evidenziando le differenze tra metodi sequenziali e non sequenziali, con esempi pratici. Infine,

la tesi si concluderà con una riflessione sulle principali scoperte e sulle prospettive future dell'intelligenza artificiale nello sport.

1.2 Contesto generale dell'analisi delle prestazioni sportive

Negli ultimi anni, la crescente disponibilità di dati digitali ha trasformato il modo in cui vengono analizzate le prestazioni sportive. Allenatori, atleti e analisti utilizzano sempre più dati per monitorare, valutare e migliorare le performance. I sistemi tecnologici, come la goal-line technology nel calcio, non solo supportano gli arbitri nelle decisioni, ma forniscono anche una quantità impressionante di dati che possono essere sfruttati per analisi più approfondite.

Grazie all'evoluzione tecnologica, la raccolta e l'elaborazione di grandi quantità di dati è diventata più semplice e accessibile. Tuttavia, la vera sfida sta nella capacità di analizzare questi dati in modo efficace, al fine di trarre conclusioni che possano migliorare le prestazioni atletiche e tattiche. Il ruolo dei Big Data nello sport non si limita solo al monitoraggio delle performance, ma estende la sua influenza anche alla pianificazione strategica, alla prevenzione degli infortuni e alla gestione delle risorse umane.

1.3 L'evoluzione dei Big Data nello sport

L'adozione dei Big Data ha rivoluzionato il settore sportivo, consentendo l'analisi di un'enorme mole di informazioni in tempo reale. Allenatori e scienziati dello sport utilizzano tecnologie avanzate per analizzare le prestazioni degli atleti con un livello di precisione mai visto prima. Questi dati possono essere utilizzati per identificare schemi di gioco, valutare le condizioni fisiche degli atleti e prevedere le prestazioni future.

L'implementazione dei Big Data ha anche favorito lo sviluppo di nuove metodologie di allenamento basate sull'analisi scientifica dei dati. Gli algoritmi di machine learning e deep learning permettono agli esperti di predire con maggiore precisione i risultati di una partita o di un'intera stagione, basandosi su dati raccolti in precedenza e in tempo reale. Questo permette agli allenatori di pianificare in modo più dettagliato le strategie da adottare.

Questi sviluppi hanno anche favorito una crescita significativa nelle tecniche statistiche e computazionali; l'IA, combinata con la potenza dei big data, consente una pianificazione più efficace e una previsione accurata dei risultati delle prestazioni. Nel contesto sportivo, **machine learning (ML)** e **deep learning (DL)** stanno giocando un ruolo sempre più rilevante nell'analisi delle prestazioni, nella strategia e nella pianificazione atletica.

Il machine learning è uno strumento flessibile che permette di creare modelli capaci di apprendere dai dati storici e migliorare nel tempo. Nell'analisi sportiva, questi modelli sono utilizzati per molteplici applicazioni, come la previsione delle prestazioni individuali, l'identificazione di schemi tattici nelle squadre avversarie e la prevenzione di infortuni. Il ML consente decisioni basate su dati reali, dando un vantaggio strategico. Ad esempio, nel calcio e nel basket, gli algoritmi di ML sono impiegati per analizzare le partite o le stagioni, prevedere risultati o scoprire talenti. Questi modelli monitorano metriche come velocità, energia spesa e interazioni tra i giocatori, offrendo approfondimenti difficili da ottenere con metodi tradizionali [1].

Il deep learning, una branca avanzata del ML, utilizza reti neurali artificiali per identificare pattern complessi all'interno di grandi dataset. Grazie alla loro struttura multi-layered, le reti neurali profonde gestiscono dati come video e tracciamenti in tempo reale. Un esempio è il riconoscimento automatico dei comportamenti degli atleti, attraverso tecniche di **computer vision**, o la previsione di azioni future basate su dati storici

[2]. Tuttavia, uno dei limiti del DL è che i modelli non spiegano facilmente i fattori chiave che influenzano le prestazioni, il che rende difficile interpretare le decisioni strategiche basate su questi modelli.

1.4 Rischi e Limiti

Le sfide e i limiti legati all'uso di machine learning (ML) e deep learning (DL) nello sport derivano principalmente dalle complessità insite nelle tecniche di apprendimento automatico e dalla natura del contesto sportivo, che spesso è influenzato da molteplici variabili imprevedibili.

1.4.1 Overfitting

Uno dei problemi più comuni è l'overfitting, che si verifica quando un modello di ML o DL si adatta troppo bene ai dati di allenamento, catturando non solo i pattern rilevanti ma anche il "rumore" specifico di quel set di dati. Questo porta a modelli che funzionano molto bene su dati già visti, ma che falliscono quando applicati a nuovi dati, come ad esempio quelli provenienti da partite future o da diversi contesti sportivi. Questo può significare che le previsioni sulle prestazioni future degli atleti o sui risultati delle partite non siano accurate quando il modello è esposto a situazioni reali [3]. Per mitigare l'overfitting, è fondamentale utilizzare tecniche come la **regolarizzazione** e l'**uso di set di validazione e test** separati dai dati di allenamento.

1.4.2 Black Box (mancanza di interpretabilità)

Il deep learning, sebbene molto potente nel riconoscere pattern complessi, è spesso considerato una "black box". Questo termine si riferisce alla difficoltà di interpretare esattamente come i modelli di deep learning arrivino a determinate decisioni o previsioni. Questo può essere un problema serio

nel contesto sportivo, dove gli allenatori e gli analisti non solo desiderano sapere “cosa” un modello prevede, ma anche “perché”. Ad esempio, se un modello predice che un giocatore avrà una performance sotto la media, è importante sapere quali fattori (ad esempio, affaticamento fisico, prestazioni passate, condizioni ambientali) hanno influenzato questa previsione per prendere decisioni di conseguenza. La mancanza di trasparenza nei modelli DL può ridurre la fiducia nelle loro previsioni, specialmente in contesti dove le decisioni strategiche devono essere giustificate [4].

1.4.3 Problemi di generalizzazione

Un'altra sfida chiave è la generalizzazione. I modelli di ML e DL sono spesso addestrati su set di dati specifici che potrebbero non riflettere appieno tutte le condizioni che si verificano in un contesto sportivo reale. Per esempio, un modello potrebbe essere addestrato su dati di una singola stagione o di una specifica lega, ma le condizioni e le dinamiche di gioco possono cambiare radicalmente da una stagione all'altra, o da una lega all'altra. Ciò rende difficile l'applicazione universale dei modelli e potrebbe richiedere un costante riaddestramento per garantire che il modello rimanga aggiornato e accurato [5].

1.4.4 Qualità dei dati e questioni etiche

La qualità dei dati e le considerazioni etiche rappresentano due aspetti cruciali e strettamente collegati nell'uso del machine learning (ML) e del deep learning (DL) nello sport. I modelli di ML e DL sono efficaci solo quanto i dati che li alimentano. Dati incompleti, rumorosi o raccolti in modo non uniforme possono portare a previsioni inaccurate e interpretazioni fuorvianti. Ad esempio, nelle analisi sportive, la precisione del tracciamento delle performance atletiche può variare in base alla tecnologia utilizzata, alle condizioni di gioco e persino alla disponibilità di dati biometrici, come la frequenza cardiaca o la fatica dell'atleta. Se questi dati

non vengono raccolti in modo coerente e affidabile, i modelli di ML e DL potrebbero produrre risultati errati o difficilmente applicabili in contesti reali [6].

Inoltre, la raccolta e l'utilizzo di grandi quantità di dati sportivi pongono importanti questioni etiche, soprattutto quando si tratta di **privacy e consenso informato**. Le informazioni sensibili degli atleti, come le misurazioni biometriche, i dati personali o le performance, possono essere soggette a violazioni della privacy se non gestite correttamente. Questo è particolarmente rilevante nel contesto sportivo, dove gli atleti potrebbero non avere il pieno controllo su come e quando i loro dati vengono utilizzati. Ad esempio, alcuni algoritmi di ML potrebbero perpetuare **bias preesistenti** nelle valutazioni delle prestazioni, favorendo alcuni giocatori rispetto ad altri in modo ingiusto o discriminatorio [6]. Inoltre, la trasparenza nei processi di raccolta e gestione dei dati diventa fondamentale per garantire l'integrità delle analisi e il rispetto dei diritti degli atleti.

Per affrontare queste sfide, è necessario stabilire linee guida etiche chiare sull'uso dei dati, garantendo che gli atleti siano consapevoli di come i loro dati vengono raccolti e utilizzati. È essenziale sviluppare meccanismi per proteggere la privacy e implementare politiche di consenso informato. Al tempo stesso, occorre lavorare su metodologie di raccolta dati che garantiscano alta qualità e affidabilità, riducendo il rumore e le lacune che potrebbero compromettere l'efficacia degli algoritmi di ML e DL [7].

Capitolo 2

Metodologie di Raccolta Dati tramite IA

2.1 Problemi e Rischi durante la Raccolta Dati

Come detto all'interno del Capitolo 1.4.4, l'implementazione di tecnologie avanzate per la raccolta dei dati nello sport presenta numerosi vantaggi, ma anche diverse sfide e problematiche. Una delle sfide principali riguarda la qualità dei dati raccolti: i sensori e i dispositivi utilizzati generano continuamente dati, anche in situazioni non ottimali, come in ambienti non rappresentativi delle reali condizioni di gioco. Questo può portare a dati non contestualizzati che non rispecchiano le dinamiche sportive effettive[8].

Ad esempio, nel calcio, l'uso di sensori GPS sugli atleti ha consentito una maggiore comprensione delle distanze percorse e delle velocità raggiunte. Tuttavia, la qualità dei dati raccolti può variare a seconda dell'ambiente (ad esempio, campi con copertura GPS limitata) e della corretta calibrazione dei dispositivi. Un problema comune con il GPS è la perdita di segnale durante le partite, soprattutto in stadi chiusi o con strutture che bloccano il segnale satellitare. Inoltre, se i dati non sono raccolti seguendo un protocollo rigoroso, il rischio di ottenere risultati errati o

incompleti è elevato.

Un'altra sfida significativa è la gestione di grandi volumi di dati. L'analisi di dati in tempo reale richiede non solo potenza di calcolo ma anche l'uso di tecniche avanzate di intelligenza artificiale, come il machine learning o il deep learning, per ridurre la dimensionalità dei dati e individuare i pattern più rilevanti. Tuttavia, questa riduzione della complessità può portare alla perdita di informazioni critiche per le decisioni tattiche. Ad esempio, durante una partita di basket, ridurre i dati relativi al posizionamento dei giocatori a un solo parametro come la velocità media può trascurare le dinamiche tattiche complesse come i cambi di direzione o le accelerazioni improvvise [9].

Per mitigare questi rischi, è essenziale progettare accuratamente la procedura di acquisizione dati, definendo il compito di valutazione, le tecnologie appropriate e i metodi di raccolta. Questa progettazione dovrebbe sempre considerare la natura specifica del compito sportivo, così da garantire che i dati raccolti siano rappresentativi della realtà della prestazione.

2.2 Analisi Notazionale

2.2.1 Principi dell'analisi

L'**analisi notazionale** (*notational analysis*) è una tecnica consolidata per l'analisi delle prestazioni sportive, basata sull'osservazione sistematica e la codifica delle azioni registrate durante competizioni o allenamenti. Questo metodo, ampiamente utilizzato in sport come il calcio, il rugby e il tennis, consente di registrare variabili chiave come passaggi riusciti, tiri in porta o movimenti difensivi.

Un esempio pratico di analisi notazionale può essere osservato nel tennis, dove gli analisti tracciano la frequenza e la direzione dei colpi, la lunghezza degli scambi e le percentuali di successo sui vari tipi di ser-

vizio. Attraverso software avanzati come Dartfish e Hudl Sportscode, i dati raccolti possono essere utilizzati per fornire feedback in tempo reale agli allenatori, consentendo loro di adattare le tattiche di gioco durante la competizione.

2.2.2 Validità e Affidabilità dell'Analisi Notazionale

La **validità** e l'**affidabilità** sono componenti essenziali per garantire che l'analisi notazionale fornisca informazioni utili e riproducibili.

La validità di un'analisi notazionale si riferisce alla capacità del sistema di misurare ciò che è stato progettato per misurare. Se, per esempio, l'obiettivo è tracciare i movimenti difensivi in una partita di calcio, l'analisi deve essere in grado di catturare con precisione tali azioni, senza interferenze o errori di interpretazione. Secondo Hughes e Bartlett (2002)[10], la validità di un sistema di analisi notazionale dipende dall'accuratezza con cui le categorie di prestazione sono definite e osservate.

L'affidabilità, d'altra parte, riguarda la consistenza delle misurazioni nel tempo. In altre parole, se lo stesso evento viene analizzato più volte, da diversi osservatori o dalla stessa persona in momenti diversi, i risultati dovrebbero essere simili o uguali. L'affidabilità di un sistema di analisi notazionale può essere valutata attraverso il calcolo della coerenza *intra-osservatore* (ripetizione della stessa analisi dallo stesso osservatore) e *inter-osservatore* (confronto tra analisi di osservatori differenti). Hughes e Franks (2008) [11] suggeriscono che la differenza tra le osservazioni dovrebbe essere minima per garantire un alto grado di affidabilità.

Nel contesto del rugby, Duthie, Pyne e Hooper (2003)[12] hanno studiato l'affidabilità dell'analisi del tempo-movimento in dieci giocatori durante 12 partite. I risultati hanno mostrato che le categorie di movimento a bassa intensità, come il camminare, erano misurate con maggiore affidabilità rispetto a quelle più intense, come lo sprint.

Per minimizzare questi errori, Hughes e Franks (2008)[11] raccomandano l'uso di metodi di confronto sistematici tra le analisi. Ad esempio, si consiglia di applicare un metodo percentuale per calcolare l'errore relativo tra le osservazioni intra e inter-osservatore, utilizzando la seguente formula:

$$ErrorePercentuale = \frac{\sum |V_1 - V_2|}{V_{mean}} \times 100\% \quad (2.1)$$

dove V_1 e V_2 sono le variabili osservate e V_{mean} è la media delle due variabili .

L'adozione di procedure standardizzate, la formazione degli osservatori e l'uso di strumenti tecnologici avanzati sono tutti elementi fondamentali per ridurre gli errori e migliorare la qualità delle analisi.

2.3 Tracciamento Automatico 2D e 3D, e Sensori

Il **tracciamento automatico** rappresenta un significativo passo avanti nell'analisi delle prestazioni sportive, poiché consente di monitorare il movimento degli atleti senza la necessità di un intervento umano costante. Questo tipo di tracciamento si avvale di tecnologie avanzate come videocamere multiple, sensori indossabili e sistemi di visione artificiale, che permettono di raccogliere dati in tempo reale o post-elaborazione, offrendo una grande quantità di informazioni su posizione, velocità, accelerazioni, interazioni tra atleti e molto altro.

Il monitoraggio automatico in 2D e 3D è fondamentale in sport come il calcio, il basket e il rugby, dove la capacità di tracciare più atleti contemporaneamente su ampi spazi di gioco è essenziale per l'analisi delle dinamiche di squadra. Questo tipo di monitoraggio consente di ottenere dati dettagliati sulle distanze percorse, i cambi di direzione e le strategie tattiche implementate dalle squadre.

Le tecnologie di tracciamento utilizzate nello sport possono essere suddivise in due principali categorie: **sistemi basati su telecamere** e **sistemi basati su sensori indossabili**. I sistemi basati su telecamere, come i sistemi multi-videocamera e i sistemi optocinetici, offrono la possibilità di tracciare il movimento degli atleti con una precisione elevata, ricostruendo le azioni in 2D o 3D. D'altra parte, i sistemi basati su sensori indossabili, come i GPS e le unità di misura inerziale (*Inertial Measurement Unit IMU*), permettono di monitorare gli atleti per periodi di tempo prolungati e in ampi spazi aperti, anche in condizioni ambientali complesse.

2.3.1 Sistemi Multi-Videocamera

I **sistemi multi-videocamera** utilizzano più telecamere posizionate in diversi punti del campo per catturare da angolazioni differenti i movimenti degli atleti. Questi sistemi permettono la ricostruzione 2D o 3D delle azioni, con un'alta precisione spaziale. La tecnica di **direct linear transformation(DLT)** è spesso utilizzata per convertire i dati bidimensionali acquisiti dalle telecamere in modelli tridimensionali, consentendo agli analisti di esaminare in dettaglio le traiettorie e i movimenti degli atleti. Questa tecnologia trova applicazione in molti sport, tra cui calcio, basket e nuoto.

Un esempio di utilizzo dei sistemi multi-videocamera è il progetto **Second Spectrum**[13], adottato nella *NBA*. Second Spectrum si avvale di diverse telecamere ad alta definizione installate nei palazzetti, che seguono i giocatori e la palla durante la partita, fornendo dati in tempo reale su ogni movimento. Il sistema permette di tracciare la posizione di ogni giocatore e confrontarla con le sue precedenti performance, valutando parametri come la velocità, la distanza percorsa e la qualità delle azioni difensive o offensive. Inoltre, grazie all'analisi avanzata delle traiettorie, gli allenatori possono ricevere suggerimenti tattici in tempo reale, facilitando la presa di decisioni durante la partita. Ad esempio, i **Los Angeles**

Lakers hanno utilizzato Second Spectrum per migliorare la propria difesa, studiando come i giocatori si muovono in relazione ai loro avversari e ottimizzando così le strategie difensive e offensive.

Nel calcio, il sistema **TRACAB**[14], utilizzato in competizioni come la *Premier League inglese* e la *Bundesliga tedesca*, è uno dei più avanzati per il tracciamento automatico degli atleti. Questo sistema si basa su una rete di telecamere ad alta definizione disposte intorno al campo, che acquisiscono dati spaziali-temporali di ogni giocatore e della palla a una frequenza di 25 fotogrammi al secondo. I dati vengono successivamente elaborati per fornire una mappatura dettagliata dei movimenti individuali e collettivi, consentendo di analizzare la copertura del campo, la velocità media, gli sprint e le accelerazioni di ciascun giocatore. Studi condotti da Mortensen e Bornn (2020)[15] hanno dimostrato come TRACAB sia stato utilizzato per monitorare l'attività dei giocatori del *Chelsea FC*, con un'accuratezza tale da permettere la valutazione delle distanze percorse, delle fasi di alta intensità e dei movimenti tattici della squadra.

Nel nuoto, i sistemi multi-videocamera sono utilizzati per analizzare la tecnica dei nuotatori, specialmente per migliorare la biomeccanica e ottimizzare la fase di bracciata. La tecnologia consente di valutare l'efficienza di ogni ciclo di bracciata e di identificare eventuali aree di miglioramento nella tecnica. Il sistema di analisi video 3D sviluppato da **Qualisys** permette di tracciare con precisione i movimenti dei nuotatori sia sopra che sotto la superficie dell'acqua, fornendo dati utili per ottimizzare la tecnica e ridurre la resistenza idrodinamica.

2.3.2 TV Broadcast Tracking

La **TV Broadcast Tracking Technology** rappresenta un notevole passo avanti nell'analisi delle prestazioni sportive, specialmente nel calcio. Questo sistema consente di monitorare automaticamente i movimenti della palla e dei giocatori per il 40%-60% del tempo di una partita ufficiale

utilizzando le trasmissioni televisive standard, senza richiedere attrezzature aggiuntive negli stadi o la supervisione di un operatore umano [16]. La posizione dei giocatori viene rilevata dalla telecamera principale di trasmissione attraverso una calibrazione dinamica del campo, che si aggiorna man mano che la telecamera si sposta durante la partita. Tuttavia, la generazione dei dati non è continua, poiché alcuni giocatori possono uscire dall'inquadratura della telecamera, specialmente durante i replay o i primi piani. Per compensare questi vuoti, il sistema impiega algoritmi di estrapolazione, basati su studi di convalida che utilizzano sistemi multi-camera di tracciamento video come riferimento [15], [16]. Dal punto di vista tecnico, il processo di tracciamento tramite trasmissione televisiva è composto da diversi passaggi chiave. Il primo passo è la segmentazione dell'inquadratura, che distingue tra riprese del gioco e replay. Successivamente, il sistema rileva e classifica giocatori, arbitri e palla in ogni fotogramma, per poi stimare l'omografia, ossia i parametri della telecamera, al fine di proiettare i movimenti rilevati sul piano del campo da calcio. Il sistema traccia poi i movimenti dei soggetti da un fotogramma al successivo e infine identifica i singoli giocatori presenti nell'inquadratura [16]. Rispetto a tecnologie più avanzate come TRACAB, il tracciamento delle trasmissioni televisive offre notevoli vantaggi in termini di costi ridotti, poiché non richiede telecamere specializzate per il tracciamento. Questo lo rende facilmente implementabile anche in stadi che non dispongono di sistemi di tracciamento avanzati.

2.3.3 Sistemi Optocinetici e Sensori

I **sistemi optocinetici** rappresentano lo standard per la cattura del movimento tridimensionale in ambienti controllati, come i laboratori di biomeccanica. Questi sistemi utilizzano telecamere a infrarossi ad alta velocità e marcatori riflettenti applicati direttamente sul corpo dell'atleta. Grazie alla loro elevata precisione, questi sistemi sono utilizzati princi-

palmente per l'analisi biomeccanica dettagliata di movimenti specifici, come il salto o la corsa.

Tuttavia, i **sensori indossabili** come i GPS e le IMU hanno rivoluzionato il tracciamento degli atleti in sport di squadra e individuali, consentendo di raccogliere dati su ampia scala e in condizioni di gara reali. Nel rugby, i dispositivi GPS sono utilizzati per monitorare la distanza percorsa e la velocità dei giocatori durante la partita, fornendo anche dati relativi agli impatti fisici. Questo tipo di informazioni è essenziale per gestire i carichi di lavoro degli atleti e prevenire sovraccarichi che potrebbero portare a infortuni. Ad esempio, uno studio condotto nel *rugby professionistico australiano* ha dimostrato che l'utilizzo dei sensori GPS ha permesso di identificare i momenti di massima intensità durante le partite, consentendo agli allenatori di adattare le sessioni di recupero e migliorare le prestazioni fisiche degli atleti [17].

Nel calcio, il sistema **Catapult** utilizza una combinazione di sensori GPS e accelerometri per monitorare i movimenti degli atleti e le loro prestazioni fisiche durante le partite e gli allenamenti. Uno studio[15] condotto su squadre della **Premier League** ha dimostrato che i dati raccolti con Catapult possono essere utilizzati per prevedere gli infortuni, monitorando i carichi di lavoro e identificando le fasi di affaticamento muscolare che precedono un infortunio. Questo ha portato a una riduzione significativa del numero di infortuni muscolari nelle squadre che hanno adottato questa tecnologia.

2.4 Variabili Ecologico-Fisiche per Catturare le Dinamiche Ambientali nella Prestazione Sportiva

2.4.1 Descrizione e Importanza

Le **variabili ecologico-fisiche** sono parametri che catturano l'interazione dinamica tra un atleta e l'ambiente in cui opera. Secondo il quadro delle dinamiche ecologiche, la prestazione di un atleta non può essere compresa isolando l'individuo, ma deve essere analizzata tenendo conto delle interazioni con il contesto ambientale. Un esempio classico di variabile ecologico-fisica è l'*angolo giocatore-palla-porta* nel calcio, che cattura il legame spaziale tra l'atleta, la palla e l'obiettivo finale[18].

2.4.2 Esempi di utilizzo

Nel *calcio*, Carrilho et al. (2020)[19] hanno analizzato gli angoli giocatore-palla-porta durante una partita della Coppa del Mondo FIFA 2018. Questa variabile ha permesso di catturare le dinamiche di squadra e prevedere i cambiamenti critici nelle prestazioni, i cambiamenti di possesso palla o i momenti decisivi che hanno portato a un gol. Utilizzando i dati di tracciamento del sistema TRACAB, gli autori hanno osservato che l'angolo giocatore-palla-porta poteva prevedere con precisione gli schemi di gioco della squadra, fornendo informazioni utili per migliorare la tattica e il posizionamento sul campo.

Nel *rugby*, uno studio[20] ha utilizzato variabili spazio-temporali per descrivere le relazioni tra gli attaccanti e i difensori. Hanno scoperto che il placcaggio e la capacità di un difensore di bloccare l'attaccante erano influenzati dall'angolo creato tra il giocatore e la linea di meta. Questa variabile ecologico-fisica ha permesso di modellare l'interazione tra i gio-

catori, consentendo una migliore comprensione delle dinamiche del gioco e suggerendo nuove strategie difensive.

Capitolo 3

Applicazioni dell'Intelligenza Artificiale nelle Scienze dello Sport

La prestazione atletica è parte di un sistema dinamico complesso con un'enorme quantità di dati sottostante (Davids et al., 2014). Pertanto, come qualsiasi altro sistema dinamico complesso, l'intelligenza artificiale ha il potenziale per svelare modelli di comportamento e interazioni tra atleti che caratterizzano prestazioni di successo in diversi sport (Beal, Norman e Ramchurn, 2019). Tuttavia, l'analisi di sistemi altamente complessi è un compito impegnativo e, sebbene la rete neurale (NN) abbia dimostrato di essere una delle soluzioni più ricorrenti per affrontarli, la sua applicabilità dipende fortemente dalla qualità dei dati forniti. La rappresentazione dei dati di input e la generalizzazione dei modelli appresi hanno un impatto cruciale sulle prestazioni degli approcci di intelligenza artificiale: una scarsa rappresentazione dei dati può portare a una diminuzione delle prestazioni di un metodo avanzato di deep learning, mentre una buona rappresentazione può migliorare persino metodi tradizionali di apprendimento automatico. Il processo di estrazione dei dati rilevanti, noto come "ingegneria delle caratteristiche", è essenziale. Le caratteristiche, che

possono essere calcolate sui dati grezzi come la velocità dell'atleta, richiedono conoscenze interdisciplinari, tra cui competenze matematiche e una comprensione del contesto sportivo.

3.1 Metriche individuali

Molti esperti concordano sul fatto che, proprio come nei sistemi collettivi auto-organizzati presenti in natura, come le colonie di formiche e gli alveari di api, la prestazione complessiva di una squadra di calcio è superiore alla somma di tutti gli individui di quella squadra (Hughes, Franks e Dancs, 2019). Tuttavia, valutare come questi singoli atleti reagiscono ai carichi competitivi, come interagiscono tra loro e come favoriscono le opportunità di segnare una rete può aiutare lo staff tecnico a impostare nuove strategie e combinazioni tra i giocatori, oltre a controllare il loro recupero per prevenire sforzi eccessivi e infortuni [21].

Le metriche individuali si concentrano sulle prestazioni di un singolo atleta, fornendo indicatori che sono essenziali per il monitoraggio diretto e per fornire feedback specifici per migliorare le capacità atletiche.

3.1.1 Misure Cinematiche

Velocità e Distanza

La posizione di un giocatore $x_i[t] \in R^2$, definita nel piano del campo di gioco, può essere scomposta nelle coordinate $x_i[t] = (x_i[t], y_i[t])$. La velocità media tra intervalli di tempo consecutivi t può essere calcolata come segue:

$$v_i[t] = \frac{|x_i[t] - x_i[t - 1]|}{\Delta t} = \frac{\sqrt{(x_i[t] - x_i[t - 1])^2 + (y_i[t] - y_i[t - 1])^2}}{\Delta t} \quad (3.1)$$

dove Δt rappresenta l'intervallo di tempo tra le due misure consecutive. La distanza percorsa dal giocatore può essere calcolata come:

$$d_i[t] = \Delta t \sum_{k=0}^t v_i[k] \quad (3.2)$$

Oltre alla distanza percorsa, metriche simili possono essere applicate per calcolare la distanza tra giocatori o dalla porta. L'associazione tra velocità media e distanza percorsa può potenziare le analisi dei giocatori ed aiutare a comprendere dati di attività differenti, come camminare e correre.

Orientamento

L'orientamento di un giocatore verso la porta avversaria può fornire informazioni aggiuntive se associate con la porta degli avversari, per comprendere specifiche azioni come passare o tirare. Considerato $x_G[t] = (x_G[t], y_G[t])$ la linea centrale posizionata in corrispondenza della porta avversaria, l'orientamento di un giocatore verso essa, $\theta_i[t]$, può essere calcolato come segue:

$$\theta_i[t] = (\delta_i[t] - a \tan 2((y_G[t] - y_i[t]), (x_G[t] - x_i[t]))) \quad (3.3)$$

dove $\delta_i[t]$ è la posizione angolare del giocatore i nel campo.

Entropia della traiettoria (Trajectory Entropy)

L'entropia della traiettoria (Trajectory Entropy) è un concetto fondamentale per comprendere la variabilità dei giocatori di calcio durante le partite. Si possono utilizzare vari metodi per analizzare la variabilità, inclusi i metodi non lineari come gli esponenti di Lyapunov[22], l'entropia di Shannon[23], l'entropia approssimata e l'entropia campionaria. Questi metodi forniscono informazioni aggiuntive sulla struttura della variabili-

tà che evolve nel tempo, rispetto ai metodi tradizionali come la deviazione standard o il coefficiente di variazione [24]. L'entropia campionaria (Sample Entropy, SampEn) è una delle metriche più semplici da calcolare per analizzare la variabilità ed è considerata una delle più imparziali tra le misure correlate all'entropia [25]. La SampEn può essere applicata per stimare la variabilità della traiettoria di un giocatore attraverso le sue posizioni spaziali nel campo da gioco.

Considerando una serie temporale unidimensionale, la posizione del giocatore i è indicata come $x_i[t]$, con la decomposizione nelle dimensioni $x_i[t] = (x_i[t], y_i[t])$ dove (x_i, y_i) rappresenta la posizione sul campo da calcio. La sequenza di vettori $u_{mi}[k]$ è definita come:

$$u_{mi}[k] = \{u_i[k], u_i[k+1], \dots, u_i[k+m-1]\}, \quad 1 \leq k \leq M - m + 1 \quad (3.4)$$

Dove M , m e ϵ sono parametri costanti. M è la lunghezza della serie temporale, m la lunghezza della sequenza da confrontare e ϵ la tolleranza, calcolata come percentuale della deviazione standard dei dati processati.

Distanza Tra Vettori

La distanza tra due sequenze di vettori $u_{mi}[k]$ è definita come:

$$d_{ui} = \max |u_i[k_1 + k] - u_i[k_2 + k]|, \quad 0 \leq k \leq m - 1 \quad (3.5)$$

Calcolo della Prossimità

Consideriamo B_{k_1} e A_{k_1} , rispettivamente, il numero di vettori $u_{mi}[k_2]$ che si trovano entro una tolleranza ϵ dal vettore $u_{mi}[k_1]$, ed il numero di vettori $u_{m+1i}[k_2]$ che si trovano entro una tolleranza ϵ dal vettore $u_{m+1i}[k_1]$, con $1 \leq k \leq M - m$, $k_1 \neq k_2$. Definito come:

$$\begin{cases} B_{k_1 i}^m(\epsilon) = \frac{B_{k_1 i}}{M-m+1} \\ A_{k_1 i}^m(\epsilon) = \frac{A_{k_1 i}}{M-m+1} \end{cases} \quad (3.6)$$

La media di queste quantità è:

$$\begin{cases} B_i^m(\epsilon) = \frac{1}{M-m+1} \sum_{k=1}^{M-m} B_{ki}^m(\epsilon) \\ A_i^m(\epsilon) = \frac{1}{M-m+1} \sum_{k=1}^{M-m} A_{ki}^m(\epsilon) \end{cases} \quad (3.7)$$

Fomula finale per la SampEn

Infine, l'entropia campionaria può essere calcolata come:

$$\text{SampEn}_i(m, \epsilon) = -\ln \left(\frac{A_i^m(\epsilon)}{B_i^m(\epsilon)} \right) \quad (3.8)$$

[26]

3.1.2 Metriche Fisiologiche

Le metriche fisiologiche sono suddivise in due categorie principali: metodi invasivi e metodi non invasivi. Nei metodi non invasivi, l'obiettivo è monitorare i parametri fisiologici senza influire sulle condizioni ecologiche della prestazione.

Frequenza cardiaca

La frequenza cardiaca è un indicatore chiave per monitorare l'intensità dell'attività fisica e viene misurata in battiti per minuto (BPM). La **frequenza cardiaca a riposo** (HR_{rest}) rappresenta il ritmo cardiaco basale e dovrebbe essere misurato al risveglio. Negli atleti tende a diminuire con l'allenamento aerobico, e conoscere questa metrica è fondamentale per valutare le prestazioni atletiche e eseguire screening per problemi di salute.

La **frequenza cardiaca massima** (HR_{max}) è raggiunto durante attività fisiche intense e può essere utilizzato per valutare la resistenza cardiovascolare di un atleta. Attraverso questi due concetti, è possibile calcolare la **riserva di frequenza cardiaca** (HR_R) per l'atleta i come segue:

$$HR_{R_i} = HR_{max_i} - HR_{rest_i} \quad (3.9)$$

Considerando i valori HR di un atleta i nel tempo t , la frequenza cardiaca può essere normalizzata per ogni istante t con la seguente equazione:

$$HR_{norm_i}[t] = \frac{HR_i[t] - HR_{rest_i}}{HR_{max_i} - HR_{rest_i}} \quad (3.10)$$

Oltre alla frequenza cardiaca, viene spesso utilizzata per monitorare i carichi di allenamento la variabilità della frequenza cardiaca (HVR). L'analisi di questa può essere effettuata calcolando una serie temporale degli intervalli tra battiti cardiaci successivi (**RR**). Se aggiornato ogni istante t per ciascun giocatore i , la serie temporale **RR** può essere espressa come una variabile che varia nel tempo, $RR_i[t]$. Questo può essere monitorato tramite tecnologie indossabili, come le fasce toraciche per il monitoraggio della frequenza cardiaca. La variabilità media della frequenza cardiaca ($mHRV_i[t]$) è la metrica più comune e si calcola come la media mobile semplice di **RR** _{i} [t] :

$$mHRV_i[t] = \frac{1}{t} \sum_{k=1, k \in N}^t RR_i[k] \quad (3.11)$$

La **deviazione standard di tutti gli intervalli NN** (intervalli normali RR), nota come **SDNN** _{i} [t], indica l'HRV globale e può essere calcolato come segue:

$$SDNN_i[t] = \sqrt{\frac{1}{t-1} \sum_{k=1, k \in N}^t (RR_i[k] - mHRV_i[k])^2} \quad (3.12)$$

La **radice quadrata della differenza massima successiva** degli intervalli RR ($RMSSD_i[t]$) permette di stimare le variazioni della frequenza cardiaca in registrazioni a breve termine degli intervalli RR.

$$RMSSD_i[t] = \sqrt{\frac{1}{t} \sum_{k=1}^{t-1} (RR_i[k+1] - RR_i[k])^2} \quad (3.13)$$

Elettromiografia (EMG)

L'elettromiografia (EMG) è una tecnica utilizzata per studiare i potenziali elettrici generati dai muscoli durante contrazioni concentriche, eccentriche o isometriche [27]. **La elettromiografia di superficie (sEMG)**, che misura i segnali attraverso la pelle, è particolarmente rilevante per la riabilitazione, lo sport e anche l'ergonomia [28]. Nell'acquisizione del segnale EMG, è fondamentale considerare il comfort dell'atleta nella scelta della tecnologia più adeguata, in particolare concentrandosi sui muscoli degli arti inferiori. Le soluzioni come il Myontec MBody 3 permettono di raccogliere più canali di attività muscolare delle gambe. L'attività muscolare può essere quantificata attraverso il valore dell'ampiezza del segnale ($A_i^{ch}[t]$) per ogni canale (ch) tra il numero totale di canali (ch_{tot}). Questo valore rappresenta l'attività elettrica del muscolo in quel momento, catturata tramite elettrodi posti sulla superficie della pelle.

Il quadrato medio (Root Mean Square - RMS) di un segnale EMG di un determinato canale viene spesso adottato per quantificare l'attività elettrica nella contrazione muscolare. Mostra le variazioni nella forza impiegata dall'atleta (i) nel tempo (t). La sua rappresentazione matematica è la seguente:

$$EMG_{RMSi}^{ch}[t] = \sqrt{\frac{1}{t} \sum_{k=1}^t (A_i^{ch}[k])^2} \quad (3.14)$$

Vi è una relazione tra il quadrato medio (RMS) dell'EMG e la forza

impiegata, ma tale relazione tende ad essere più lineare nei piccoli muscoli[29]. Nei muscoli più grandi, che richiedono un migliore reclutamento motorio, la relazione diventa non lineare poiché le variazioni di ampiezza del segnale EMG non corrispondono alle variazioni di forza.

3.2 Metriche di Gruppo

Negli sport di squadra, le metriche di gruppo sono utilizzate per valutare il comportamento collettivo della squadra. Queste metriche spaziali e di rete possono essere utilizzate per ottimizzare le tattiche di gioco e migliorare la collaborazione tra i giocatori.

3.2.1 Metriche Spazio-Temporali

Le metriche spazio-temporali sono utili per fornire informazioni rilevanti su come i team, considerati come un sistema collettivo, si comportano nel tempo durante una partita[30]. Queste metriche possono essere usate come un importante strumento per migliorare le opportunità di coaching, permettendo di rilevare e agire sulle debolezze della squadra durante la partita. Tra le metriche principali troviamo il baricentro ponderato (weighted centroid), l'indice di allungamento ponderato (weighted stretch index) e l'area di superficie (surface area).

Baricentro Ponderato

Nel calcio e in altri sport di squadra, il centroid (baricentro) è spesso calcolato come la posizione media geometrica di tutti i giocatori di una squadra. Come prima, le coordinate della posizione del giocatore i nel campo sono scomposte nelle sue dimensioni $x_i[t] = (x_i[t], y_i[t])$. Il baricentro ponderato può essere calcolato in funzione della posizione geometrica media di tutti i giocatori N della squadra, ponderata con il peso $w_i[t]$ di ciascun

giocatore, come segue:

$$\begin{pmatrix} x[t] \\ y[t] \end{pmatrix} = \frac{1}{\sum_{i=1}^N w_i[t]} \begin{pmatrix} \sum_{i=1}^N w_i[t] x_i[t] \\ \sum_{i=1}^N w_i[t] y_i[t] \end{pmatrix} \quad (3.15)$$

In questo caso, $w_i[t]$ è il fattore di ponderazione associato a ciascun giocatore, che è definito in funzione della distanza euclidea dalla palla, come segue:

$$w_i[t] = 1 - \frac{\sqrt{(x_i[t] - x_b[t])^2 + (y_i[t] - y_b[t])^2}}{d_{max}[t]} \quad (3.16)$$

Dove $x_b[t]$ e $y_b[t]$ sono le coordinate della palla e $d_{max}[t]$ è la distanza massima del giocatore più lontano dalla palla al tempo t .

Indice di allungamento ponderato

Il Weighted Stretch Index rappresenta un parametro che misura l'espansione o la contrazione spaziale della squadra nelle direzioni longitudinale e laterale del campo da gioco [31]. Per calcolare l'indice di stretch ponderato, possiamo utilizzare la seguente formula:

$$s_{ind}[t] = \frac{\sum_{i=1}^N w_i[t] d_i[t]}{\sum_{i=1}^N w_i[t]} \quad (3.17)$$

dove $d_i[t]$ rappresenta la distanza euclidea tra il giocatore i e il centroide della squadra, espressa come:

$$d_i[t] = \sqrt{(x_i[t] - x[t])^2 + (y_i[t] - y[t])^2} \quad (3.18)$$

Il valore di $w_i[t]$ rappresenta il peso attribuito a ciascun giocatore, in base alla sua distanza dal pallone o al suo ruolo nella fase difensiva o offensiva. Questo concetto si basa sull'idea che la posizione dei giocatori rispetto al centroide e al pallone ha un impatto sulla loro influenza complessiva sulla dinamica della squadra [32]. Il Weighted Stretch Index può quindi essere

calcolato come la media delle distanze tra ogni giocatore e il centroide del team, ponderate per l'importanza relativa di ciascun giocatore.

3.3 Network Metrics

La letteratura sportiva presenta diversi approcci per analizzare le interazioni dei giocatori attraverso la teoria dei grafi, utilizzata per modellare le reti [31]. Uno studio significativo di Bourbousson et al. [33] ha utilizzato la teoria dei grafi per analizzare la connettività tra giocatori di basket, evidenziando come il coordinamento della rete si basi su interazioni locali. Questo approccio è stato esteso ad altri sport come la pallanuoto, dove il comportamento collettivo di successo richiede un'elevata interazione tra giocatori della stessa squadra [34].

In alcuni casi, come nelle iperreti sviluppate da Ramos et al. [35], vengono analizzate simultaneamente le interazioni cooperative e competitive tra compagni di squadra e avversari. Queste reti utilizzano una matrice di adiacenza ponderata:

$$\mathbf{A}(t) = \begin{bmatrix} a_{11}(t) & a_{12}(t) & \dots & a_{1N}(t) \\ a_{21}(t) & a_{22}(t) & \dots & a_{2N}(t) \\ \vdots & \vdots & \ddots & \vdots \\ a_{N1}(t) & a_{N2}(t) & \dots & a_{NN}(t) \end{bmatrix} \quad (3.19)$$

dove N è il numero di giocatori e a_{ij} rappresenta il livello di interazione tra il giocatore i e il giocatore j nel tempo t . Questa matrice è fondamentale per descrivere il comportamento della squadra [36]. Le interazioni possono essere definite, ad esempio, dai passaggi riusciti tra i giocatori, con per un passaggio riuscito dal giocatore al giocatore, e zero altrimenti. Questo approccio genera reti dirette o digrafi, come descritto da van Den Brink [37]. Tuttavia, per semplificare l'analisi, spesso vengono considerati due grafici non orientati: uno per i passaggi eseguiti e un altro per i

passaggi ricevuti [38].

Un esempio di rete basata sulle giocate offensive di una determinata squadra è illustrato 3.1. Per effettuare questa analisi è stato utilizzato *Rstudio*. Nello specifico, questa rete considera i giocatori, inclusi i titolari e sostituti, e mostra le interazioni tra i giocatori sotto forma di passaggi. I dati utilizzati sono stati presi dal sito StatsBomb Open Data e riguardano la partita di calcio tra Liverpool e Tottenham del 27 Ottobre 2019, ed in particolare riguardano i passaggi effettuati tra giocatori della squadra *Liverpool*. Le dimensioni dei vertici rappresentano il grado, mentre lo spessore degli archi ($a_{ij}(t) = a_{ji}(t)$) indicano il numero di passaggi tra i giocatori i e j .

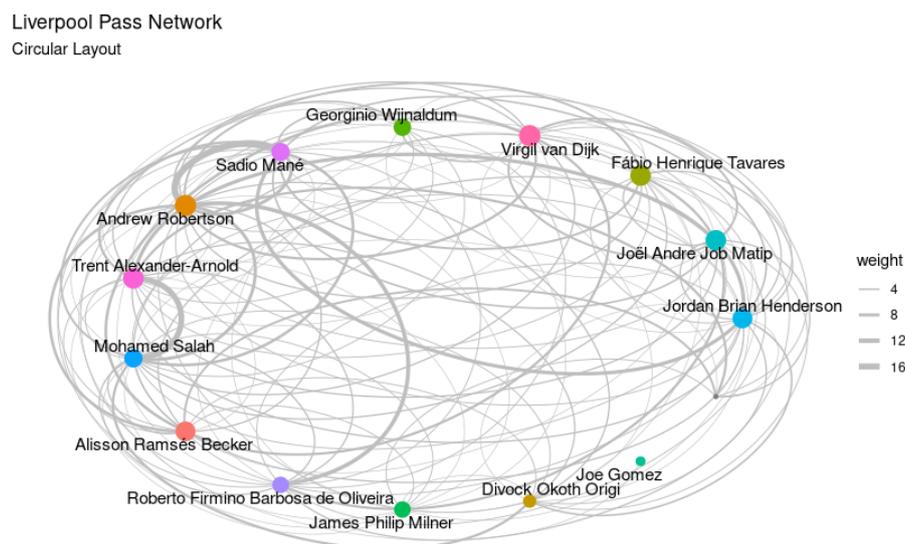


Figura 3.1: Esempio di rappresentazione grafica di una rete di passaggi tra giocatori. Grafico realizzato con la funzione *ggraph* dell'omonimo pacchetto

Come visibile in figura 3.1 i due terzini della squadra *Andrew Robertson* e *Trent Alexander-Arnold* sono giocatori molto importanti per numeri di passaggi a cui partecipano. Si può anche notare come i giocatori con cui condividono più passaggi, siano rispettivamente *Sadio Mané* e *Mohamed Salah* ovvero i giocatori offensivi lungo la loro stessa fascia, questo a significare come la tattica della squadra potrebbe essere quella

di sviluppare il gioco lungo le fasce. La semplice osservazione grafica non è sufficiente per quantificare il contributo individuale dei giocatori, pertanto è necessario adottare una serie di metriche computazionali. La teoria delle reti o, più in generale, la teoria dei grafi rappresenta un potente strumento per l'analisi di queste interazioni [36].

Giocatore	Grado in Entrata	Grado in Uscita	Grado Totale
Virgil van Dijk	7	12	19
Andrew Robertson	9	12	21
Trent Alexander-Arnold	10	11	21
Sadio Mané	11	8	19
Mohamed Salah	13	8	21
Jordan Brian Henderson	9	10	19

Tabella 3.1: Tabella dei 6 giocatore con grado maggiore.

Già dall'analisi visiva del grafico era stato possibile farsi un'idea abbastanza corretta di chi fossero i giocatori con grado più elevato. Le connessioni più forti e frequenti risultavano visibili, confermando in modo intuitivo quali giocatori avessero un maggior coinvolgimento nelle dinamiche di squadra.

Connettività Scalata

La connettività scalata del giocatore al tempo può essere calcolata sommando i pesi delle connessioni tra il giocatore e tutti gli altri giocatori:

$$\kappa_i(t) = \sum_{j=1}^N a_{ij}(t) \quad (3.20)$$

La connettività scalata misura quanto il giocatore contribuisca all'interazione collettiva, consentendo di identificare i giocatori più cooperativi.

Calcoliamo la connettività Scalata della rete precedente:3.1

Giocatore	in Entrata	in Uscita	Totale
Virgil van Dijk	21	33	54
Andrew Robertson	33	57	90
Trent Alexander-Arnold	18	49	67
Sadio Mané	54	28	82
Mohamed Salah	57	18	75
Jordan Brian Henderson	27	31	58

Tabella 3.2: Tabella dei 6 giocatore con Connettività maggiore.

Possiamo osservare che i giocatori con un grado maggiore sono anche quelli con una connettività scalata più elevata. Tuttavia, dal grafico iniziale non era immediatamente chiaro quali giocatori avessero una connettività più alta, poiché la distribuzione visiva non rendeva evidenti queste differenze a prima vista. Solo attraverso un'analisi quantitativa più approfondita è stato possibile individuare chiaramente tali relazioni.

Coefficiente di Clustering

Il coefficiente di clustering indica il grado in cui i compagni di squadra tendono a cooperare tra loro. È calcolato come:

$$C_i(t) = \frac{2 \times \text{numero di triangoli con il giocatore } i}{\text{numero di coppie di giocatori collegati a } i} \quad (3.21)$$

Un alto coefficiente di clustering significa che i compagni di squadra del giocatore cooperano tra loro in maniera stretta.

Rango Globale

Il rango globale di un giocatore si calcola come una funzione della connettività e del coefficiente di clustering:

$$\mathcal{R}(t) = \sum_{i=1}^N \kappa_i(t) \times C_i(t) \quad (3.22)$$

Densità della Rete

La densità della rete si calcola come:

$$D(t) = \frac{\sum_{i,j} a_{ij}(t)}{N \times (N - 1)} \quad (3.23)$$

Dove N è il numero di giocatori. Una densità prossima a 1 indica che tutti i giocatori interagiscono fortemente tra loro.

Eterogeneità

L'eterogeneità della rete misura la variazione della connettività tra i giocatori e si calcola con il coefficiente di variazione della connettività:

$$\mathcal{H}(t) = \frac{\sigma(\kappa(t))}{\mu(\kappa(t))} \quad (3.24)$$

Dove σ è la deviazione standard e μ è la media della connettività.

Capitolo 4

Intelligenza artificiale per il riconoscimento di azioni e schemi nello sport

Nell'apprendimento supervisionato, un modello viene addestrato per riconoscere delle classi o etichette predefinite, che nel contesto sportivo possono rappresentare un atleta, un'azione o altre categorie utili nel processo decisionale per gli allenatori e i team tecnici. Come descritto nel Capitolo 3, i dati cinematici e fisiologici raccolti dalla prestazione atletica vengono utilizzati per estrarre le caratteristiche rilevanti. Questi insiemi di caratteristiche, che possono derivare da dati temporali (come la cinematica) o metriche computazionali, vengono etichettati manualmente da esperti umani e archiviati come set di dati [39].

4.1 Classificazione non-Sequenziale

I metodi di apprendimento supervisionato, come le Support Vector Machines (SVM) o le Artificial Neural Network (ANN, reti neurali artificiali), vengono addestrati utilizzando tali set di dati per associare un gruppo di caratteristiche a una determinata classe (fase di training). Quando ven-

gono ricevuti nuovi dati non etichettati, il modello addestrato è in grado di abbinarli a una delle classi già note, basandosi sull'esperienza accumulata nella fase di test. Nello sport, i set di caratteristiche di dimensione nota vengono calcolati da serie temporali (ad esempio, dati cinematici o fisiologici) e non dipendono dal numero di campioni acquisiti. Questo approccio è denominato classificazione non sequenziale, ed è ampiamente adottato per la sua semplicità rispetto a quella sequenziale.

La principale forza della classificazione non sequenziale rispetto a quella sequenziale risiede nella quantità ridotta di dati necessari. In questo tipo di classificazione, ogni caratteristica è rappresentata da un singolo valore numerico, riducendo così la complessità del modello. In altre parole, la complessità computazionale di un classificatore non-sequenziale rimarrà la stessa per un certo numero di caratteristiche e classi, che rimane invariato all'interno dello stesso set di dati.

Tuttavia, il successo di questi classificatori dipende dalle caratteristiche dei dati, come la dimensione del dataset, la distribuzione delle classi e la quantità di rumore presente. Tra i classificatori tradizionali, l'albero decisionale, il modello a miscela gaussiana [40] e l'algoritmo k-nearest neighbor [41] sono ampiamente utilizzati. Tuttavia, i metodi più popolari nel contesto sportivo sono le Support Vector Machines (SVM) e le Reti Neurali Artificiali (ANN), grazie alla loro flessibilità e capacità di apprendimento su dati complessi.

4.1.1 Support Vector Machine

Le SVM sono tecniche di machine learning sviluppate da Vladimir Vapnik, utilizzate per risolvere problemi di classificazione lineare o non lineare [42]. L'SVM cerca di identificare il miglior iperpiano che separa due o più classi di dati, massimizzando il margine tra i vettori di supporto. La distanza tra i vettori di supporto è chiamata margine che può essere duro o morbido a seconda che i dati siano linearmente separabili o meno

[43].

In un caso semplice e unidimensionale, con una singola caratteristica per classe, le classi relative agli atleti possono essere facilmente separate con una linea. Tuttavia, molti problemi nel mondo reale sono non lineari. In questi casi, l'SVM utilizza una funzione kernel per mappare i dati in uno spazio a dimensioni superiori, consentendo una separazione più efficace. Per problemi SMV non lineari, è richiesta la mappatura dei dati di addestramento, qui indicati come X_{data} dallo spazio di input Φ a uno spazio di caratteristiche ad alta dimensione:

$$\Phi : X_{data} \longrightarrow X \quad (4.1)$$

La funzione kernel, K , calcola il prodotto interno dei vettori (x_p, y_p) appartenenti allo spazio delle caratteristiche, come si può vedere nell'equazione seguente:

$$K(x_p, y_p) = \Phi(x_p) * \Phi(y_p) \quad (4.2)$$

Schölkopf (2001)[44] ha osservato che la funzione kernel può definire una distanza nello spazio di input, come mostrato nella formula:

$$d_{\text{kernel}}^2(x_p, y_p) = (\Phi(x_p) * \Phi(y_p))^2 = K(x_p, x_p) - 2K(x_p, y_p) + K(y_p, y_p) \quad (4.3)$$

Questo mostra che la funzione Kernel, $K(x_p, y_p)$, può essere descritta come un grado di similarità tra i campioni x_p e y_p .

4.1.2 Reti Neurali Artificiali

Le reti neurali artificiali (ANN) sono un modello di apprendimento ispirato alla struttura del cervello umano. Ogni rete è costituita da neuroni organizzati in strati: strato di input, strati nascosti e strato di output. I dati

passano attraverso i diversi strati, con pesi associati alle connessioni tra i neuroni, che vengono aggiornati durante l'addestramento per migliorare le previsioni della rete, tramite tecniche come la retropropagazione dell'errore [45]. Le ANN possono essere sia supervisionate che non supervisionate, qui parlo solo di quelle supervisionate, dove conosciamo l'output corretto della y , dato l'input x , e dove cambiamo i pesi tra i neuroni per rendere la classificazione più efficiente.

Apprendimento con Reti Neurali

Consideriamo un esempio in cui una rete viene addestrata su sequenze di passaggi in una partita di calcio [46]. Il processo di apprendimento inizia con la definizione di pesi iniziali casuali e procede con l'aggiornamento dei pesi basato sull'errore calcolato. La formula per l'errore è data da:

$$e = y_{out} - y_{out}^{cal} \quad (4.4)$$

dove y_{out}^{cal} è l'output calcolato dalla rete e y_{out} è l'output atteso. L'aggiornamento dei pesi avviene tramite la seguente equazione:

$$w_k = w_k + \eta \cdot e \cdot x_{inp_k} \quad (4.5)$$

dove x_{inp_k} rappresenta l'input del neurone k , e η è il tasso di apprendimento. Il processo di apprendimento continua fino a quando l'errore viene ridotto a un livello accettabile.

Output Calcolato dalla Rete

Il calcolo dell'output della rete avviene moltiplicando gli input per i pesi associati ai neuroni, secondo la seguente formula:

$$y_{out}^{cal} = \sum_{k=1}^n x_{inp_k} \cdot w_k + w_0 \quad (4.6)$$

dove w_0 è il bias della rete.

Applicazione nello Sport

Le reti neurali sono utilizzate per analizzare sequenze di azioni sportive, come i passaggi tra i giocatori durante una partita di calcio. Ad esempio, una rete neurale può classificare una sequenza di passaggi come "successo" o "fallimento" in base ai movimenti dei giocatori. Questo tipo di analisi è particolarmente utile per identificare schemi di gioco vincenti e ottimizzare le strategie di squadra.

Esempio di Rete Neurale per la classificazione di Sequenza Offensiva

Immaginiamo di avere un modello di rete neurale per classificare il successo di una giocata offensiva (1 se ha successo, -1 se non ha successo) in una partita di calcio. In questo esempio, la rete è stata addestrata con due sequenze di input:

$$(x_{inp_1}, x_{inp_2}, x_{inp_3}) = (0, 0, 1), \quad y_{out} = -1 \quad (4.7)$$

$$(x_{inp_1}, x_{inp_2}, x_{inp_3}) = (1, 1, 0), \quad y_{out} = 1 \quad (4.8)$$

Con i pesi iniziali definiti come:

$$w_1 = 0.4, \quad w_2 = -0.6, \quad w_3 = 0.6, \quad w_0 = 0.5 \quad (4.9)$$

$$e = y_{out} - y_{out}^{cal} \quad (4.10)$$

Per la sequenza (1,1,0), l'output calcolato y_{out}^{cal} è dato da:

$$y_{out}^{cal} = 1 \times (1.2) + 1 \times (0.2) + 0 \times (-0.2) - 1 \times (0.5) = 0.7 > 0 \quad (4.11)$$

Questo implica che la giocata è classificata come successo, in linea con le aspettative del modello.

Processo di Aggiornamento dei Pesì

Durante l'addestramento, i pesi vengono aggiornati se l'output calcolato y_{out}^{cal} non corrisponde a quello atteso y_{out} . Supponiamo che per l'input (0,0,1), il valore calcolato sia:

$$y_{out}^{cal} = 0 \times (0.4) + 0 \times (-0.6) + 1 \times (0.6) - 1 \times (0.5) = 0.1 \quad (4.12)$$

Dato che $y_{out}^{cal} = 1$, mentre $y_{out}^{cal} = -1$, è necessario aggiornare i pesi. I nuovi pesi dopo l'aggiornamento diventano:

$$w_1 = 1.2, \quad w_2 = 0.2, \quad w_3 = -0.2 \quad (4.13)$$

Dopo aver addestrato la rete con queste due sequenze, possiamo testarla su nuove sequenze, come (0,0,0), (1,1,1), (1,0,0) e (0,1,1) per valutare la capacità del modello di classificare correttamente le sequenze offensive come successi o fallimenti. Anche se si tratta di un esempio semplificato, mostra come la rete neurale imita le decisioni umane attraverso il processo di apprendimento.

4.2 Classificazione Sequenziale

La classificazione sequenziale è un problema di modellazione in cui i dati in input sono dinamici. I dati variano nel tempo e la classificazione sequenziale mira a classificare la categoria in cui i dati si inseriscono, utilizzando sequenze nello spazio o nel tempo come input.

A differenza delle classificazioni non sequenziali, che lavorano con dati di grandezza fissa, le classificazioni sequenziali affrontano dati di

dimensione sconosciuta e variabile. All'interno dello sport, ci sono numerose applicazioni in cui l'insieme delle funzionalità è spesso basato sul tempo. Ad esempio, dal movimento di calciare una palla si possono estrarre sia caratteristiche statiche, che dipendenti dal tempo. La dimensione della sequenza è variabile poiché, prendendo come esempio un calcio di rigore, la durata del processo non è sempre la stessa. Nei modelli di classificazione sequenziale, l'output corrente dipende dall'input precedente nell'intero set di dati. Per evitare una complessità crescente dovuta all'elaborazione di tutte le informazioni, sono stati proposti metodi di machine learning, come *l'ensemble learning* e *il deep learning*.

4.2.1 Ensemble Learning

La maggior parte dei metodi di classificazione basano la propria funzione sulla probabilità risultante dal loro output. Al fine di aumentare le prestazioni complessive di classificazione (bias) e diminuire la varianza, la combinazione probabilistica di diversi classificatori è stata ampiamente esplorata, dando origine al termine *ensemble system*. I classificatori scelti per far parte di questo sistema devono soddisfare alcune condizioni, poiché classificatori con basso bias tendono ad avere una varianza elevata. La classificazione d'insieme ha ricevuto particolare attenzione per la sua versatilità nel risolvere diverse tipologie di problemi del mondo reale[47].

I metodi di classificazione ensemble possono essere sequenziali o paralleli. Nella classificazione sequenziale, gli apprenditori di base vengono generati in sequenza per sfruttare al meglio le dipendenze tra i modelli. Nei metodi di ensemble paralleli, i modelli sono generati in parallelo, incoraggiando l'indipendenza tra i classificatori, riducendo così l'errore, facendo la media degli output di modelli multipli. I metodi di classificazione ensemble possono anche essere omogenei (usando lo stesso tipo di classificatore) o eterogenei, in cui i modelli di base sono differenti[48].

In questa sezione, viene descritto il Dynamic Bayesian Mixture Model

(DBMM), che sfrutta il concetto di combinazione dinamica dei classificatori, combinando le probabilità condizionali risultanti da ogni classificatore per ottenere il miglior risultato possibile. Durante il processo di classificazione nel DBMM, a ciascun classificatore viene assegnato un peso in base alle conoscenze precedenti acquisite durante l'addestramento. Questo peso funge da livello di confidenza e viene aggiornato nel tempo. A ogni istante t , l'insieme dei classificatori utilizza la probabilità bayesiana per valutare il contributo di ciascun classificatore al risultato finale. Il risultato di questo modello ensemble viene presentato come una somma ponderata delle distribuzioni combinate dei diversi modelli in uno solo. Supponendo che \mathcal{X} rappresenti i dati di input degli apprenditori di base e che l'output di ciascun classificatore contenga la previsione della classe, tali risultati vengono combinati e memorizzati in y_{out}^{comb} . Per ogni passo temporale t , la classificazione risultante del DBMM è rappresentata da:

$$P(C(t) | \mathcal{X}(t)) = \beta \cdot M_{trans} \cdot \sum_{cl=1}^{CL} w_{cl}(t) \cdot P_{cl}(\mathcal{X} | C(t)) \quad (4.14)$$

dove β è il fattore di normalizzazione:

$$\beta = \frac{1}{\sum P(C_j(t)|C_j(t-1)) \times \sum_{j=1}^N w_i(t) \times P_{cl}(\mathcal{X}|C_j(t))} \quad (4.15)$$

necessario per il continuo aggiornamento del livello di confidenza, e j è l'indice per l'insieme dei posteriori di un certo classificatore cl . M_{trans} è il modello per la probabilità di transizione tra stati delle classi. Questo modello può rappresentare *a priori* nel DBMM, come ciclo probabilistico dinamico, dove il correntete *a posteriori* diventa il nuovo *a priori*

Durante l'addestramento, i modelli di base emettono una probabilità che un dato insieme di caratteristiche debba appartenere a una certa classe.

Il livello di confidenza viene assegnato a ciascun classificatore usando un peso basato sull'entropia di ogni classificatore di base. L'entropia è data dalla seguente equazione:

$$En_{cl}(L) = - \sum L_j \cdot \log(L_j) \quad (4.16)$$

dove L_j rappresenta un insieme con probabilità condizionata $P_{cl}(C(t)|\mathcal{X})$. Dopo aver ottenuto l'entropia $En_{cl}(L)$, il peso w_{cl} per ciascun classificatore viene aggiornato seguendo due passaggi:

Calcolo del valore globale del peso:

$$\forall w_{cl}, w_{cl}(t) = 1 - \frac{En_{cl}}{\sum_{cl=1}^{CL} En_{cl}} \quad (4.17)$$

dove $En_{cl}(L)$ è il valore corrente dell'entropia.

Normalizzazione del peso:

$$w_{cl}(t) = \frac{w_{cl}(t)}{\sum_{cl=1}^{CL} w_{cl}(t)} \quad (4.18)$$

Questo assicura che il sistema possa aggiornare localmente i pesi per ogni intervallo di tempo. Il DBMM assume che il sistema abbia una memoria basata su Markov per ottenere informazioni temporali dall'insieme dei posteriori per ciascun classificatore di base, il che è essenziale per la classificazione sequenziale. In questo contesto, si utilizza la probabilità condizionata dei classificatori precedenti per aggiornare i pesi al tempo $t-1$, come descritto nella formula seguente:

$$w_{cl}(t) = \frac{w_{cl}(t-1) \times P(w_{cl_{new}} | En_{cl}(L))}{\sum_{cl=1}^{CL} w_{cl}(t-1) \times P(w_{cl_{new}} | En_{cl}(L))} \quad (4.19)$$

dove $w_{cl}(t)$ è la stima del peso aggiornato da ogni classificatore ad ogni istante di tempo e $w_{cl}(t)$ è dato dai pesi precedenti calcolati al tempo $t-1$. In questo modo, i pesi di ogni classificatore di base vengono aggiornati costantemente durante il processo di classificazione.

Differenze con le Reti Neurali

La principale differenza tra questo modello e una rete neurale artificiale (ANN) potrebbe non essere subito evidente, poiché le reti neurali tradizionali funzionano bene con dati statici. Tuttavia, la complessità aumenta notevolmente quando si utilizzano dati sequenziali. In questo contesto, i modelli ensemble offrono un vantaggio, poiché non si basano solo sull'output di un singolo modello, ma combinano più output, fornendo una maggiore robustezza nella classificazione di dati sequenziali. Ad esempio se sono scelti tre classificatori anti correlati e una delle reti commette un errore di classificazione durante una delle prove, le altre due reti possono risolvere l'errore. Altri tipi di reti neurali, come le reti neurali ricorrenti (RNN, recurrent neural network), sono progettate specificamente per gestire dati sequenziali.

4.3 Recurrent Neural Networks (RNN) e LSTM

Le Recurrent Neural Networks (RNN) sono un tipo di rete neurale dove l'output di una cella diventa l'input per la successiva, mantenendo quindi la memoria delle informazioni passate [49]. La decisione effettuata dal RNN al tempo $t-1$ è memorizzato in un layer nascosto, che poi influenzerà le decisioni al tempo t . Questo tipo di rete è utile per la classificazione sequenziale, come ad esempio nel riconoscimento delle prestazioni sportive. Il processo di portare avanti la memoria è modellato con la seguente equazione:

$$h(t) = \sigma(W \cdot \mathcal{X}(t) + U \cdot h(t-1)) \quad (4.20)$$

Dove, $h(t)$ è lo stato nascosto al tempo t , $\mathcal{X}(t)$ è l'input al tempo t , W e U sono le matrici di peso, σ è la funzione di attivazione.

Tuttavia, nelle RNN tradizionali, l'informazione si deteriora velocemente con il tempo, problema noto come vanishing gradient [50], che si manifesta quando l'input aumenta di dimensioni, causando una decrescita della sensibilità delle unità nascoste con il tempo. Questo porta la rete a dimenticare informazioni precedenti, riducendo la capacità di apprendere dipendenze a lungo termine.

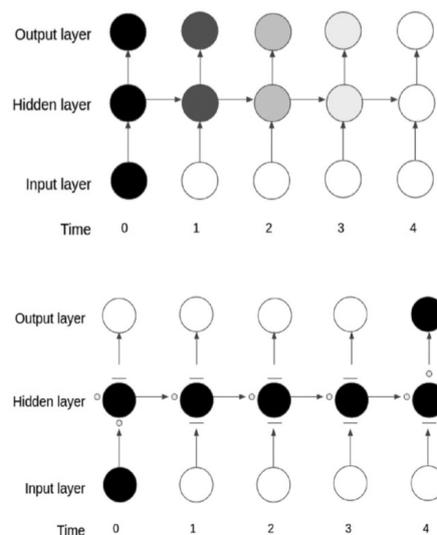


Figura 4.1: (Sopra) esempio di RNN vanishing problem, (sotto) esempio di conservazione dell'informazione con LSTM[51]

4.3.1 Long Short-Term Memory (LSTM)

L'LSTM (Long Short-Term Memory) affronta questo problema grazie ai suoi **gate** che regolano il flusso delle informazioni, permettendo alla rete di conservare elementi rilevanti più a lungo. Nel contesto sportivo, le RNN e le LSTM possono essere utilizzate per classificare azioni complesse, come attacchi o contrattacchi, basandosi su variabili temporali quali la posizione cartesiana di un giocatore e il lato del campo. Rispetto alle RNN tradizionali, le LSTM risultano più adatte a catturare sequenze temporali più lunghe, come nel caso di contrattacchi. Ogni cella ha tre principali strati di gate:

- **Forget Gate:** decide quali informazioni mantenere o dimenticare.

Consideriamo ad un certo istante t , il neurone di input $\mathcal{X}(t)$, e l'output $h(t)$. Il forget gate layer può essere all'istante t può essere descritto come segue:

$$f_g(t) = \sigma(W_f \cdot [h(t-1), \mathcal{X}(t)] + b_f) \quad (4.21)$$

dove σ è la funzione di attivazione sigmoidea, e W_{fg} e b_{fg} denotano i pesi e il bias dello strato.

- **Input Gate:** $i(t)$ decide quali informazioni aggiornare nella memoria della cella. $\tilde{C}(t)$ vettore contenente i nuovi valori candidati da aggiungere allo stato:

$$i(t) = \sigma(W_i \cdot [h(t-1), \mathcal{X}(t)] + b_i) \quad (4.22)$$

$$\tilde{C}(t) = \tanh(W_c \cdot [h(t-1), \mathcal{X}(t)] + b_c) \quad (4.23)$$

dove $W_i, b_i, W_c,$ e b_c denotano i pesi e bias delle funzioni sigmoidea e tanh, rispettivamente.

- **Stato della Cella:** lo stato della cella viene aggiornato in base alle informazioni nuove e precedenti.

$$C(t) = f_g(t) \cdot C(t-1) + i(t) \cdot \tilde{C}(t) \quad (4.24)$$

- **Output Gate:** determina l'output della cella. Lo strato sigmoideale decide quali parti dello stato della cella vanno all'output. Poi, lo strato tanh spinge i valori dalla cella stato a essere tra -1 e 1 , e li moltiplica per l'output del gate sigmoideale. Può essere calcolato come segue:

$$o(t) = \sigma(W_o \cdot [h(t-1), \mathcal{X}(t)] + b_o) \quad (4.25)$$

$$h(t) = o(t) \cdot \tanh(C(t)) \quad (4.26)$$

dove $o(t)$ è l'attivazione dell'output gate e $h(t)$ è il neurone di output ad un certo istante t . W_o and b_o rappresentano i pesi e i bias, rispettivamente, senza l'output gate.

Le reti Long Short-Term Memory(LSTM) hanno una struttura a catena come le reti neurali ricorrenti (RNN), ma con tre livelli di gate che contengono funzioni di attivazione sigmoideale, che permettono alla rete di apprendere quali informazioni mantenere o dimenticare nel tempo.

4.4 Esempio con confronto DBMM e LSTM

Un esempio di utilizzo delle tecniche di classificazione non sequenziale e sequenziale, lo possiamo trovare in uno studio descritto da Rodrigues [52], dove è stato utilizzato un approccio combinato tra due modelli di classificazione: il Dynamic Bayesian Mixture Model (DBMM) e la Long Short-Term Memory (LSTM). Questo esperimento è stato condotto per comprendere meglio come i giocatori si comportano durante la partita, fornendo informazioni preziose per allenatori, fisioterapisti e tutto il personale tecnico al fine di prendere decisioni rapide ed efficaci.

Scopo dello studio

L'obiettivo è stato triplice:

1. Esplorare la fattibilità dell'integrazione di dati provenienti da tecnologie indossabili (Myontech's Mbody3 e Ingeniarius's TraXports).

2. Determinare le caratteristiche più adeguate per identificare le azioni come correre, correre con la palla, camminare, camminare con la palla, passare, tirare e saltare.

3. Confrontare le prestazioni dei due algoritmi di classificazione sequenziale e non sequenziale: LSTM e DBMM.

Raccolta Dati e Setup Sperimentale

I dati sono stati raccolti durante quattro partite di futsal in un torneo di due giorni, coinvolgendo 22 atleti maschi. Solo uno degli atleti è stato equipaggiato con i sensori combinati per tracciare dati posizionali e fisiologici. La sincronizzazione tra video e dati ha permesso di associare manualmente ogni azione svolta dal giocatore ai dati raccolti.

Metodologia e Struttura del Dataset

Come dati in input per i metodi di classificazione sequenziale, sono state considerate nove metriche computazionali individuali tempo dipendenti: velocità, distanza e orientamento verso la porta avversaria, che sono state misurate dai dati cinematici estratti da TraXports, e dai valori normalizzati di attivazione muscolare acquisiti dagli arti inferiori dall'atleta con Mbody3.

Per garantire una varietà nei dati di addestramento e test, il dataset è stato suddiviso in modo casuale al 70% per l'addestramento e il 30% per il test, ripetendo questa suddivisione per 30 volte. In tal modo, è stato possibile ridurre il rischio di overfitting. Le prestazioni del DBMM e della LSTM sono state confrontate per ogni suddivisione. Dai risultati, è emerso che il DBMM ha superato la LSTM, con un'accuratezza complessiva dell'88,5% rispetto al 66%,1 della LSTM.

		Confusion Matrix							
Output Class	Running	45	1	2	7	0	0	0	81.1%
		14.0%	0.3%	0.6%	2.2%	0.0%	0.0%	0.0%	18.9%
	Running w/ ball	1	13	1	2	0	0	0	75.7%
		0.3%	4.0%	0.3%	0.6%	0.0%	0.0%	0.0%	24.3%
	Passing	1	0	16	2	0	0	0	84.1%
		0.3%	0.0%	5.0%	0.6%	0.0%	0.0%	0.0%	15.9%
	Walking	8	3	5	195	1	1	1	91.1%
		2.5%	0.9%	1.6%	60.6%	0.3%	0.3%	0.3%	8.9%
	Walking w/ ball	0	0	0	1	7	0	0	81.5%
		0.0%	0.0%	0.0%	0.3%	2.2%	0.0%	0.0%	18.5%
Shoting	0	0	0	0	0	3	0	81.7%	
	0.0%	0.0%	0.0%	0.0%	0.0%	0.9%	0.0%	13.8%	
Jumping	0	0	0	0	0	0	6	87.6%	
	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	1.9%	12.4%	
		81.2%	76.5%	66.6%	94.0%	85.8%	68.0%	79.9%	88.5%
		18.8%	23.5%	33.4%	6.0%	14.2%	32.0%	20.1%	11.5%
		Running	Running w/ ball	Passing	Walking	Walking w/ ball	Shoting	Jumping	
		Target Class							

		Confusion Matrix							
Output Class	Running	7	4	2	13	0	0	0	26.9%
		2.2%	1.2%	0.6%	4.0%	0.0%	0.0%	0.0%	73.1%
	Running w/ ball	2	2	3	2	1	1	0	18.2%
		0.6%	0.6%	0.9%	0.6%	0.3%	0.3%	0.0%	81.8%
	Passing	1	0	14	3	2	1	2	60.9%
		0.3%	0.0%	4.3%	0.9%	0.6%	0.3%	0.6%	39.1%
	Walking	43	10	0	187	5	1	2	75.4%
		13.4%	3.1%	0%	58.1%	1.6%	0.3%	0.6%	24.6%
	Walking w/ ball	0	0	0	1	0	0	0	0.0%
		0.0%	0.0%	0.0%	0.3%	0.0%	0.0%	0.0%	100%
Shoting	2	1	3	1	0	0	0	0.0%	
	0.6%	0.3%	0.9%	0.3%	0.0%	0.0%	0.0%	100%	
Jumping	0	0	2	0	0	1	3	50.0%	
	0.0%	0.0%	0.6%	0.0%	0.0%	0.3%	0.9%	50.0%	
		12.7%	11.8%	58.3%	90.3%	0.0%	0.0%	42.9%	66.1%
		87.3%	88.2%	41.7%	9.7%	100%	100%	57.1%	33.9%
		Running	Running w/ ball	Passing	Walking	Walking w/ ball	Shoting	Jumping	
		Target Class							

Figura 4.2: Tabella di errata classificazione: (sopra) DBMM, (sotto) LSTM[51]

Conclusioni

Questo esperimento ha mostrato che, contrariamente alle aspettative generali secondo cui i modelli di deep learning come la LSTM dovrebbero superare i modelli ensemble, la presenza di dati poco rappresentativi ha penalizzato il modello LSTM. La matrice di confusione nell'immagine 4.2 evidenzia come alcune azioni, come *corsa con la palla*, siano state classificate con maggiore accuratezza nel DBMM rispetto alla LSTM, dimostrando che quest'ultimo richiede un dataset più omogeneo e ampio per ogni azione per ottenere risultati ottimali.

Capitolo 5

Previsione delle Azioni e dei Profili delle Prestazioni

La previsione viene spesso affrontata quando i dati di input sono legati al tempo, ovvero quando i dati sono una sequenza di osservazioni nel tempo. Il modello predittivo osserva ogni elemento della sequenza e tenta di prevederne il valore in base alle osservazioni precedenti. L'analisi degli eventi temporali apre molte possibilità per le aziende o le squadre sportive, in quanto può aiutare a prevedere eventi come vincere o perdere una partita, o prevedere correttamente il comportamento dei clienti. Da un punto di vista statistico, essere in grado di prevedere quando una squadra segnerà o addirittura quanti gol segnerà è una caratteristica molto importante, specialmente per il mercato delle scommesse [53].

Per la previsione, è necessario utilizzare le informazioni conosciute derivanti dalle azioni passate e combinarle con altri fattori, come il vantaggio casalingo, il gioco di squadra, il numero di infortuni, le prestazioni individuali e collettive, tra le altre variabili. Un approccio predittivo richiede una grande quantità di dati, soprattutto se si utilizza un approccio di deep learning. Questo può rappresentare un problema, ad esempio, nel calcio, dove le squadre giocano 38 partite di campionato all'anno e incontrano la stessa squadra al due volte. Tuttavia, per modelli di deep

learning servirebbero molti più dati di partite giocate, specialmente tra le stesse squadre.

Uno degli obiettivi principali nelle previsioni riguardanti una partita è la capacità di prevedere possibili infortuni durante un match, nonostante l'imprevedibilità che caratterizza lo sport [54][55]. Gli infortuni durante una partita possono essere suddivisi in due tipologie: di contatto e di non contatto. Gli infortuni da contatto sono soggetti a più fattori esterni e sono i più difficili da prevedere, mentre quelli di non contatto sono più semplici da prevedere. Per indagare la possibilità di prevedere infortuni, sono stati proposti diversi metodi computazionali, tra cui approcci di machine learning, sistemi dinamici e tecniche di reti neurali[56].

Come la classificazione, la previsione può essere ottenuta adottando metodi sequenziali o non sequenziali. Di seguito viene analizzata la convergenza dei metodi di classificazione DBMM e LSTM, trattati nel capitolo precedente, per valutare se una previsione veloce possa essere considerata una previsione a breve termine.

5.1 Analisi di Convergenza

L'analisi di convergenza è un aspetto cruciale per comprendere le prestazioni dei modelli di intelligenza artificiale, poiché riflette l'abilità dell'algoritmo di adattarsi a un sistema dinamico che cambia. Essa indica con quale velocità i modelli convergono verso la soluzione, o se non convergono affatto, dimostrando così la loro affidabilità.

Lo studio della convergenza di un sistema è fondamentale per valutarne la fattibilità e assicurarsi che il modello sia adeguato per lavorare con dati in tempo reale. È importante sapere non solo se il modello converge, ma anche con quale velocità è in grado di prevedere il risultato.

Riprendiamo l'esempio del capitolo 4, con i modelli DBMM e LSTM addestrati su un dataset di azioni osservate durante alcune partite. Dopo l'addestramento, invece di classificare ogni prova nel suo insieme,

i modelli sono stati alimentati a ogni istante di tempo per studiarne la convergenza e valutare quanto tempo impiegano per identificare l'azione eseguita dall'atleta. Nelle figure 5.1 e 5.2 troviamo l'immagine superiore che raffigura la classe bersaglio (azione eseguita), sovrapposta alla classe prevista (azione prevista dal modello) rispettivamente per DBMM e LSTM.

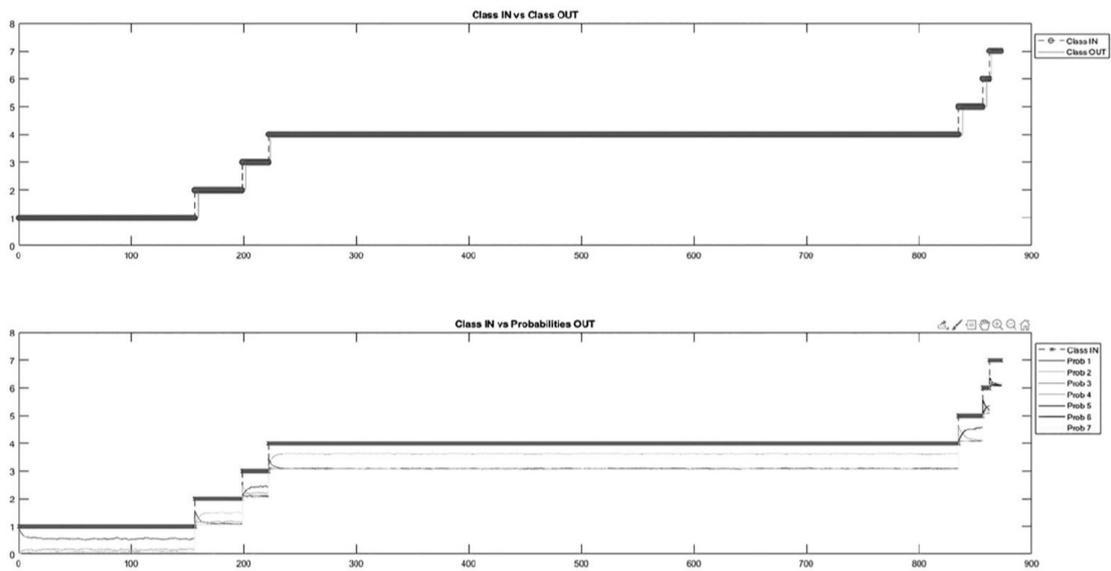


Figura 5.1: Analisi di convergenza di DBMM[51]

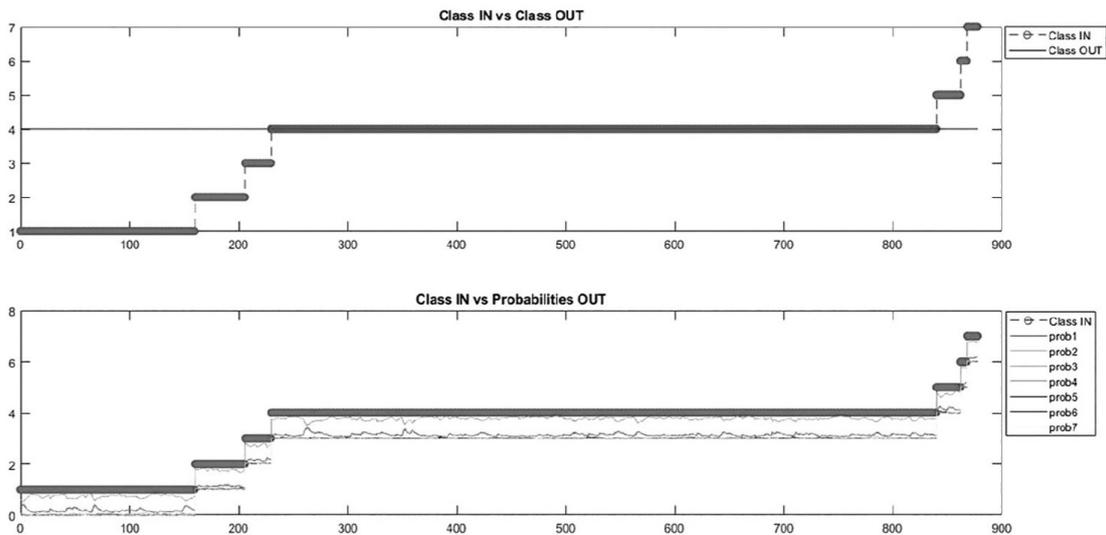


Figura 5.2: Analisi di convergenza di LSTM[51]

Allo stesso modo, l'immagine inferiore delle figure 5.1 e 5.2 raffigura la classe bersaglio sovrapposta alla probabilità prevista di appartenenza a una data classe (probabilità dell'azione prevista dal modello) rispettivamente per DBMM e LSTM.

La figura 5.2 mostra che il modello LSTM non è in grado di convergere correttamente verso una data classe, ovvero non riesce a prevedere in modo affidabile l'azione corretta. Osservando l'immagine superiore, si nota come il modello LSTM interpreti la maggior parte delle sequenze in input come un'azione di camminata. Come spiegato anche nel capitolo 4, ciò è dovuto al fatto che i metodi di deep learning richiedono un elevato numero di dati di addestramento per ogni classe affinché siano affidabili, il che non è questo il caso. La convergenza del DBMM risulta quindi più consistente rispetto a quella del LSTM. Dalla figura 5.1, si può osservare che la transizione di probabilità tra le classi consente di valutare il tempo che il DBMM impiega dalla ricezione dei dati fino alla corretta classificazione (rise time, tabella 5.1).

Classes	1	2	3	4	5	6	7
Time (s)	0	2.960	2.760	1.320	3.360	3.240	1.920

Tabella 5.1: Rise time di ogni classe/azione[51]

Possiamo osservare che il DBMM converge in modo differente a seconda dell'azione che sta cercando di prevedere. La classe 1, corsa, è l'azione che riconosce più rapidamente, impiegando meno di un secondo per identificarla. Tuttavia, il modello ha più difficoltà a riconoscere se un giocatore stia passando o tirando, impiegando più di 3 secondi, azioni che, come visto nel capitolo precedente, il modello aveva più difficoltà a classificare correttamente.

Più un modello rileva rapidamente un evento, incidente o guasto, più breve sarà il tempo di risposta e maggiore sarà il margine decisionale disponibile per il team tecnico e i coach. Tuttavia, questo esempio mostra come tali approcci possano risultare limitanti nel riconoscere

eventi in corso utilizzando metriche computazionali individuali, calcolate direttamente da dati cinematici e psicologici. Nella prossima sezione, esploreremo i metodi di previsione basati su metriche di gruppo.

5.2 Prevedere il Numero di Gol Tentati e Gol Segnati

Un articolo pubblicato da Gama e altri(2020)[55] dimostra una relazione tra l'omogeneità dei passaggi tra i giocatori della stessa squadra e il numero di gol tentati e gol segnati. L'omogeneità dei passaggi viene descritta come una misura di prestazione, definita come la distribuzione equilibrata dei passaggi effettuati e ricevuti durante una partita. Nel loro articolo[55], costruiscono una relazione non lineare tra il numero di passaggi e l'abilità della squadra di muoversi lungo il campo. La logica degli autori è che, più i giocatori sono dinamici, maggiore è la possibilità di creare linee di passaggio, smantellando così la strategia difensiva avversaria e aumentando la probabilità di segnare. Gli autori hanno analizzato un insieme di dati di dieci partite ufficiali di squadre professionistiche portoghesi durante la stagione 2010/2011 della Premier League portoghese. Dai dati analizzati, sono state considerate 2578 azioni offensive, 6100 passaggi riusciti tra i giocatori offensivi, 165 tiri e 15 gol. Le interazioni tra i giocatori, rappresentate dai passaggi, sono state quantificate applicando l'entropia di Shannon (3.1.1) a una matrice di adiacenza dei passaggi 14x14 (undici titolari più tre sostituti). L'entropia è una misura della quantità di informazione presente in una variabile; in questo caso, rappresenta la variabilità dei passaggi tra le coppie di giocatori. Più alto è il valore dell'entropia, maggiore è la variabilità nei passaggi e viceversa.

Tenendo in considerazione l'analisi temporale, la matrice di adiacenza e l'entropia relativa sono state calcolate su finestre temporali di 5 minuti, e quest'ultima è stata poi fornita come input a una rete neurale a

ritardo temporale. La rete neurale è stata addestrata per produrre due output: il numero di gol tentati e il numero di gol segnati. È stato utilizzato un ritardo temporale di un minuto, il che significa che ci si aspetta che il modello preveda i gol tentati e segnati un minuto prima che si verifichino. Per valutare l'efficacia della metodologia, la decima partita non è stata inclusa nei dati di addestramento ma è stata utilizzata per la fase di validazione. La correlazione lineare di Pearson è stata applicata per quantificare l'accuratezza del metodo di apprendimento automatico, valutando l'accuratezza delle previsioni rispetto alla verità di base.

Come illustrato nella figura 5.3, l'immagine superiore mostra il comportamento del modello predittivo nel prevedere i tentativi di gol, utilizzando i valori medi dell'entropia della distribuzione dei passaggi come serie temporale di input. L'immagine inferiore si riferisce ai tentativi di gol osservati durante la decima partita, non utilizzata in fase di addestramento. Si può osservare come il modello sia stato in grado di identificare un pattern tra le variabili, cioè tra i gol tentati e l'entropia della distribuzione dei passaggi, in modo tale da poter prevedere la probabilità di un tentativo di gol con un anticipo di un minuto rispetto all'evento reale. Questo risultato dimostra la capacità del modello di anticipare eventi all'interno di una partita.

I coefficienti di correlazione lineare di Pearson, calcolati per ogni partita del set di dati, hanno mostrato una relazione lineare positiva tra le previsioni dei tentativi di gol e i tentativi di gol effettivamente osservati.

Lo stesso procedimento è stato applicato al numero di gol segnati, ma, a causa del basso numero di gol effettivamente realizzati, il modello non è stato in grado di performare altrettanto bene rispetto alle previsioni sui tentativi di gol, come illustrato nell'immagine 5.4.

I risultati mostrati, sia per il metodo basato su metriche individuali che per quello basato su metriche di gruppo, hanno rivelato una differenza significativa rispetto ai metodi di classificazione, dovuta ai numerosi fattori che contribuiscono all'imprevedibilità negli sport.

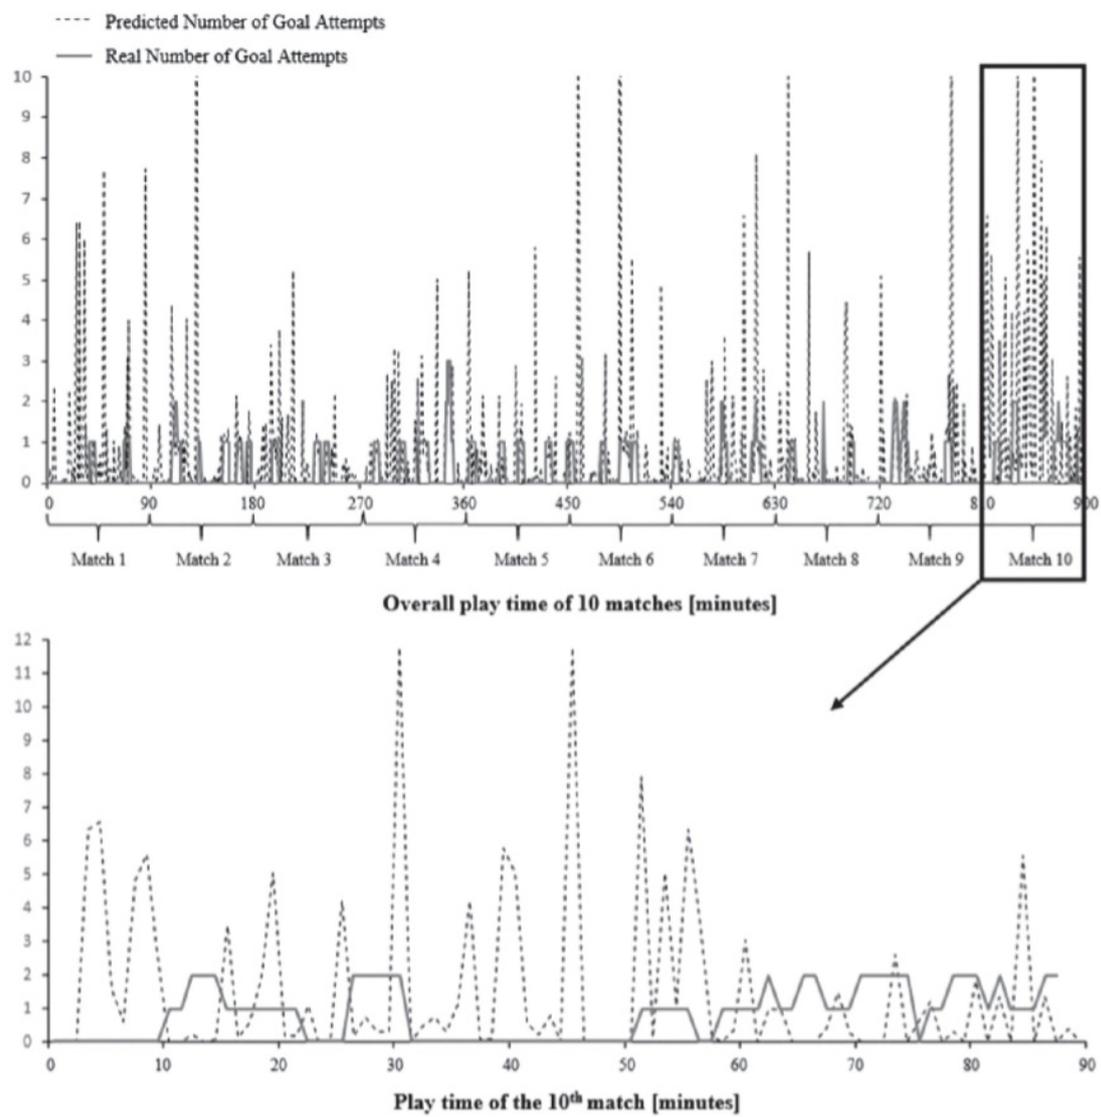


Figura 5.3: Gol tentati[51]

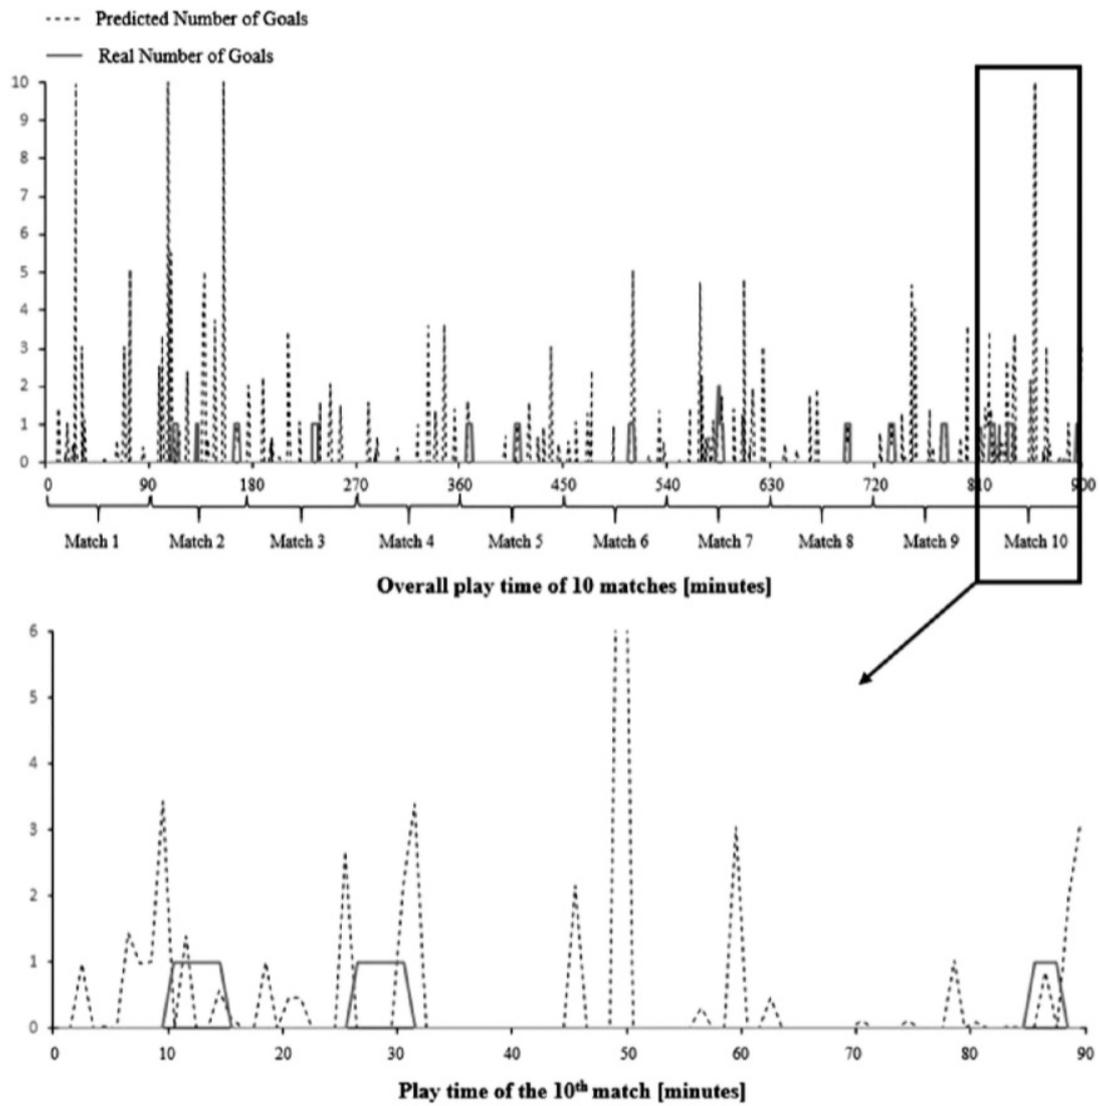


Figura 5.4: Gol segnati[51]

Capitolo 6

Sviluppi futuri dell'IA

Negli ultimi anni, lo sviluppo dell'intelligenza artificiale (IA) è stato notevole. Grazie agli investimenti sempre maggiori da parte delle grandi aziende nel settore, ci aspettiamo che l'evoluzione dell'IA continui a crescere nei prossimi anni. Un punto interessante da considerare è il ruolo di aziende come Google e Amazon nel finanziamento di ricerche avanzate in AI, che ha un impatto significativo su molteplici settori, inclusi sport e salute.

Come evidenziato nella presente tesi, uno degli ambiti in cui si è raggiunto un potenziale significativo è sicuramente la raccolta di dati. Attualmente, l'IA ha rivoluzionato i processi di raccolta, rendendoli automatici e molto più accessibili, con la capacità di gestire enormi volumi di informazioni. Studi recenti dimostrano che l'automazione nella raccolta dei dati ha ridotto significativamente il tempo necessario per l'analisi, migliorando l'efficienza operativa nelle organizzazioni.

Sicuramente, nei prossimi anni, il campo della raccolta di dati si svilupperà ulteriormente. Una direzione già in fase di sviluppo, ma che sarà sempre più presente in futuro, è quella di avere attrezzi sportivi che raccolgono direttamente i dati. Palloni da calcio e racchette da tennis sono due esempi su cui si sta già investendo molto. Potrebbe inoltre essere sviluppato in qualsiasi sport che richieda attrezzature specifiche. Ad esem-

pio, nel basket, un pallone potrebbe essere dotato di sensori in grado di registrare la velocità di un tiro, l'altezza, la posizione dal campo e la direzione. Questi dati potrebbero rivelarsi utili per analizzare la probabilità di un tiro, anche in relazione al momento del rilascio, o per identificare automaticamente il giocatore che ha effettuato un passaggio o un tiro.

Un altro ambito che sicuramente si svilupperà molto nei prossimi anni è quello degli allenatori virtuali. Ogni atleta potrebbe essere supportato da un "assistente IA" personalizzato, capace di raccogliere e analizzare in tempo reale metriche di allenamento, fisiologiche e ambientali. Questo sistema fornirebbe feedback immediati e adattivi sulle prestazioni, la fatica e il rischio di infortuni. La personalizzazione dei programmi di allenamento potrebbe portare a miglioramenti significativi delle performance. Attraverso l'analisi dei dati, il sistema sarebbe in grado di riconoscere i modelli di affaticamento specifici dell'atleta, regolando automaticamente l'intensità dell'allenamento in base alle sue condizioni fisiche e suggerendo modifiche tecniche in tempo reale per migliorare le performance e ridurre il rischio di infortuni. Questo approccio si basa su tecniche avanzate di machine learning e reinforcement learning, capaci di creare modelli di IA che non solo analizzano dati storici, ma apprendono continuamente dai dati in tempo reale.

Gli sport automobilistici sono tra i più all'avanguardia nell'utilizzo dell'IA. Nella Formula 1, ad esempio, le vetture sono dotate di oltre 200 sensori che permettono di raccogliere automaticamente una quantità elevatissima di dati. L'efficacia dei modelli di machine learning dipende completamente dalla qualità e quantità dei dati disponibili. Oltre ai dati storici, è fondamentale disporre di dati telemetrici in tempo reale, come temperatura, pressione e velocità, oltre a variabili relative a ogni pilota, come sterzate, accelerazione e frenate. Dati su tempi sul giro, velocità massime e velocità del vento contribuiscono a previsioni più accurate.

Per analisi e previsioni in tempo reale, ad esempio, si utilizza *Oracle Cloud*[57] per prevedere cambiamenti in pista e ottimizzare le strategie di

pit stop. Questo sistema sfrutta le capacità avanzate di machine learning e big data, consentendo di eseguire simulazioni Monte Carlo per testare in anticipo diverse variabili di gara, come condizioni meteorologiche e cambiamenti di superficie. Utilizzando una moderna tecnologia su Oracle Cloud Infrastructure (OCI), nel 2022 il team Red Bull[58] è riuscito ad aumentare del 25% il numero di simulazioni Monte Carlo eseguite, permettendo di esplorare più variabili e migliorare la precisione delle simulazioni. Il team utilizza *Oracle Container Engine for Kubernetes* per gestire e containerizzare queste simulazioni, eseguendole su processori ad alte prestazioni basati su Ampere Arm.

La diffusione di questo approccio anche in altri sport potrebbe rivelarsi molto importante, e l'utilizzo di sensori da parte degli atleti e nell'equipaggiamento potrebbe apportare significativi vantaggi.

Nel contesto del calcio, le simulazioni Monte Carlo possono modellare eventi come tiri in porta, passaggi riusciti e decisioni tattiche, come quando effettuare cambi o come rispondere a determinate situazioni di gioco. Utilizzando sistemi di cloud computing come Oracle Cloud Infrastructure (OCI), i team possono eseguire miliardi di simulazioni rapidamente, permettendo di aggiornare le strategie in base ai dati in tempo reale, come le condizioni di gioco, le prestazioni degli avversari e le statistiche degli atleti. Questo approccio potrebbe risolvere parte dei problemi descritti nel capitolo 5. Le simulazioni Monte Carlo consentirebbero di esplorare molte più situazioni e output, migliorando così le previsioni, nonostante il numero limitato di partite in una stagione.

Bibliografia

- [1] J. Gudmundsson e M. Horton, «Spatio-temporal analysis of team sports,» *ACM Computing Surveys*, vol. 50, n. 2, pp. 1–34, 2017.
- [2] D. Cervone, A. D’Amour, L. Bornn e K. Goldsberry, «A multiresolution stochastic process model for predicting basketball possession outcomes,» *Journal of the American Statistical Association*, vol. 111, n. 514, pp. 585–599, 2016.
- [3] Y. Song et al., «Overfitting in Sports Analytics: Challenges and Solutions,» *Journal of Quantitative Analysis in Sports*, vol. 16, n. 2, pp. 125–136, 2020.
- [4] C. Rudin, «Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead,» *Nature Machine Intelligence*, vol. 1, n. 5, pp. 206–215, 2019.
- [5] R. Rein e D. Memmert, «Big data and tactical analysis in elite soccer: Future challenges and opportunities for sports science,» *Journal of Sports Science*, vol. 34, n. 7, pp. 653–660, 2016.
- [6] A. Gullich et al., «Bias in Talent Identification: Issues in Machine Learning,» *Journal of Sports Science*, vol. 35, n. 4, pp. 299–310, 2019.
- [7] K. Woo, S. Tay e D. Proctor, «Ethical Considerations in Big Data and AI in Sports,» *International Journal of Sports Science and Coaching*, vol. 15, n. 3, pp. 245–256, 2020.

- [8] D. G. C. F. M. Couceiro M. S. e K. Davids, *A nonlinear approach to team coordination and tactical performance in soccer: From theory to practice*. Springer, 2016.
- [9] A. D. H. R. P. P. Davids K. e J. Y. Chow, «The role of ecological dynamics in analysing performance in team sports,» *Sports Medicine*, vol. 42, n. 1, pp. 1–10, 2012.
- [10] M. Hughes e R. Bartlett, «The use of performance indicators in performance analysis,» *Journal of Sports Sciences*, vol. 20, n. 10, pp. 739–754, 2002.
- [11] M. Hughes e I. M. Franks, *Essentials of Performance Analysis in Sport*. Routledge, 2008.
- [12] P. D. Duthie G. e S. Hooper, «Time motion analysis of 2001 and 2002 super 12 rugby,» *Journal of Sports Sciences*, 2003.
- [13] *Second Spectrum NBA*, Accessed September 2023. indirizzo: <https://www.secondspectrum.com/>.
- [14] *TRACAB*, Accessed September 2023. indirizzo: <https://chyron.com/products/tracab>.
- [15] A. Mortensen e L. Bornn, «Using broadcast tracking data to predict activity levels in soccer: A case study of Chelsea FC,» *International Journal of Performance Analysis in Sport*, 2020.
- [16] *SkillCorner*, Accessed September 2023. indirizzo: <https://www.skillcorner.com>.
- [17] O. R. O. H. Cummins C. e C. West, «Global positioning systems (GPS) and microtechnology sensors in team sports: A systematic review,» *Sports Medicine*, vol. 43, n. 10, pp. 1025–1042, 2013.
- [18] D. Araújo e K. Davids, «The ecological dynamics of decision making in sport,» *Psychology of Sport and Exercise*, 2018.

- [19] T. B. A. D. Carrilho E. e K. Davids, «Player-ball-goal angles: Synchronization in team sports performance,» *International Journal of Performance Analysis in Sport*, 2020.
- [20] A. D. Passos P. e K. Davids, «Interpersonal dynamics in team sports: The role of sport-specific information,» *Springer*, 2008.
- [21] P. Düking, A. Hotho, H. Holmberg, F. Fuss e B. Sperlich, «Comparison of Non-Invasive Individual Monitoring of the Training and Health of Athletes,» *Journal of Sports Science*, pp. 1245–1252, 2016.
- [22] E. Burdet, D. Franklin, R. Osu, T. Milner e M. Kawato, «Nonlinear analysis of human motor performance during golf putting,» in *Proceedings of the 28th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, IEEE, 2006, pp. 2524–2527.
- [23] S. Lopes e J Tenreiro Machado, «Exploring Shannon entropy for soccer team analysis,» in *Proceedings of the 2019 International Conference on Information Technology and Communication Systems*, ACM, 2019, pp. 25–30.
- [24] M. Couceiro, F. Clemente, F. Martins e J. Machado, «Sample entropy applied to soccer players’ tactical performance: An example for attacking plays analysis,» *Entropy*, vol. 16, n. 12, pp. 6453–6468, 2014.
- [25] J. Richman e J. Moorman, «Physiological Time-Series Analysis Using Approximate Entropy and Sample Entropy,» *American Journal of Physiology*, vol. 278, pp. 2039–2049, 2000.
- [26] V. Martínez-Cagigal, *SampEn1: A MATLAB Function for Computing the Sample Entropy of a Time Series*, <https://www.mathworks.com/matlabcentral/fileexchange/69364-sampen1>, Accessed: 2024-09-24, 2018.

- [27] P. Konrad, *The ABC of EMG: A Practical Introduction to Kinesiological Electromyography*. Noraxon INC. USA, 2005.
- [28] A. Vigotsky, I. Halperin, G. Lehman, G. Trajano e T. Vieira, «The Use of Surface Electromyography in Sport and Exercise Research: Signal Acquisition and Processing Issues,» *Frontiers in Physiology*, pp. 785–794, 2018.
- [29] J. V. Basmajian, *Muscles Alive: Their Functions Revealed by Electromyography*, 2nd edition. Baltimore: Williams & Wilkins, 1962.
- [30] F. M. Clemente et al., «Spatial-temporal metrics in football,» *Journal of Sports Science*, 2013.
- [31] J. Bourbousson, C. Sève e T. McGarry, «Team Sports and Player Interactions,» *Journal of Sports Science*, 2010.
- [32] W. Frencken, K. Lemmink, N. Delleman e C. Visscher, «Analysis of player movement in football,» *European Journal of Sport Science*, 2011.
- [33] J. Bourbousson, G. Poizat, J. Saury e C. Seve, «Space-time coordination in basketball: Integrating qualitative and quantitative methods,» *Journal of Sports Sciences*, vol. 28, n. 6, pp. 641–655, 2010.
- [34] P. Passos, D. Araújo, V. Correia e K. Davids, «Network Properties in Small-Sided Soccer Games: The Interactions between Individual and Collective Behaviors,» *Journal of Human Movement Science*, pp. 1531–1539, 2011.
- [35] S. Ramos, R. Lopes e D. Araújo, «Hypernetworks for Analyzing Cooperative and Competitive Interactions in Football Games,» *Journal of Human Movement Science*, pp. 1765–1776, 2020.

- [36] S. Brandt e U. Brefeld, «Analyzing team performances using graph theory in sports,» *Artificial Intelligence in Sports Journal*, vol. 14, n. 3, pp. 305–321, 2015.
- [37] R. van Den Brink e P. Borm, *Graph theory: A tool for network analysis*. Journal of Theoretical Biology, 2002.
- [38] J. Gama, M. Couceiro, G. Dias e V. Vaz, «A graph-theoretical approach to analyze soccer passing networks,» *IEEE Transactions on Knowledge and Data Engineering*, 2015.
- [39] S. García, J. Luengo e F. Herrera, «Data preprocessing in data mining,» *Springer*, vol. 40, pp. 27–46, 2016.
- [40] D. A. Reynolds, «Gaussian Mixture Models,» *Encyclopedia of Biometrics*, pp. 659–663, 2009.
- [41] P. Cunningham e S. J. Delany, «k-nearest neighbor classification,» *ACM Computing Surveys*, vol. 52, pp. 1–25, 2020.
- [42] M. A. Hearst, S. T. Dumais, E. Osuna, J. Platt e B. Scholkopf, «Support vector machines,» *IEEE Intelligent Systems and their Applications*, vol. 13, pp. 18–28, 1998.
- [43] E. Byvatov, U. Fechner, J. Sadowski e G. Schneider, «SVM applied to drug design,» *Journal of Chemical Information and Computer Sciences*, vol. 43, pp. 1882–1889, 2003.
- [44] B. Schölkopf e A. J. Smola, «Kernel methods in machine learning,» *Journal of Computer Science*, vol. 14, pp. 536–542, 2001.
- [45] K. L. Priddy, «Artificial Neural Networks,» *O'Reilly*, 2005.
- [46] P. Yadav, A. Yadav e R. Jain, «Artificial neural network applications in sports science,» *International Journal of Sports Science and Engineering*, vol. 8, pp. 65–73, 2014.
- [47] R. Polikar, *Ensemble learning*. Springer, 2012.

- [48] Z.-H. Zhou, *Ensemble methods: foundations and algorithms*. CRC press, 2012.
- [49] S. Agatonovic-Kustrin e R. Beresford, «Modelling and applications of artificial neural networks: an overview,» *Analytica chimica acta*, vol. 420, n. 2, pp. 121–134, 2000.
- [50] M. Schuster e K. K. Paliwal, «Bidirectional recurrent neural networks,» *IEEE Transactions on Signal Processing*, vol. 45, n. 11, pp. 2673–2681, 1997.
- [51] D. Araújo, M. Couceiro, L. Seifert, H. Sarmiento e K. Davids, *Artificial Intelligence in Sport Performance Analysis*. London: Routledge, 2021, ISBN: 9780367254377.
- [52] A. C. N. Rodrigues, A. S. Pereira, R. M. S. Mendes, A. G. Araújo, M. S. Couceiro e A. J. Figueiredo, «Using Artificial Intelligence for Pattern Recognition in a Sports Context,» *Sensors*, vol. 20, n. 11, p. 3040, 2020. DOI: 10.3390/s20113040. indirizzo: <https://doi.org/10.3390/s20113040>.
- [53] B. Skiera, «Prediction Markets: Fundamentals and Applications in Marketing,» *Journal of Marketing Research*, vol. 46, pp. 173–187, 2009.
- [54] e. a. Manuel Couceiro, «Predicting Injuries in Sports Using Machine Learning Approaches,» *International Journal of Sports Science*, vol. 6, pp. 23–34, 2016.
- [55] J. Gama, «Using Network Metrics to Predict Goals in Football,» *Journal of Sports Analytics*, vol. 6, pp. 241–257, 2020.
- [56] e. a. Pedro Fonseca, «Machine Learning for Injury Prediction in Football Players: A Computational Approach,» *Journal of Computational Science*, vol. 12, pp. 210–220, 2020.

- [57] H. Schmitz, «Planning for F1 Success: Using Oracle Cloud to Enhance Race Strategies,» *Oracle Cloud Blog*, 2022. indirizzo: <https://www.oracle.com/cloud/blog/planning-for-f1-success-using-oracle-cloud-to-enhance-race-strategies.html>.
- [58] R. B. R. Team, «Red Bull Racing and Oracle: Driving the Future of F1 with AI and Cloud Computing,» *Formula 1 Technology Magazine*, 2022. indirizzo: <https://www.redbullracing.com/ai-cloud-f1-strategy>.