



UNIVERSITÀ
DEGLI STUDI
DI PADOVA



UNIVERSITÀ DEGLI STUDI DI PADOVA

DIPARTIMENTO DI INGEGNERIA DELL'INFORMAZIONE

CORSO DI LAUREA IN INGEGNERIA DELL'INFORMAZIONE

**Studio ed implementazione di algoritmi
per l'efficienza energetica in reti
wireless 5G**

Relatore: *Prof. Marco Giordani*

Laureando: *Marco Corduff*

Anno Accademico 2024-2025

Data di Laurea: 12-11-2024

Abstract

Il seguente elaborato analizza lo stato recente delle reti wireless 5G, prestando particolare attenzione alla gestione e all'efficienza del consumo energetico di una base station 5G.

La prima parte della tesi è incentrata sulla presentazione e sulla descrizione delle tecnologie che sono state implementate per la creazione di reti 5G efficienti. Nel capitolo 2 vengono introdotti i concetti di mMIMO, Lean Carrier Design, e sleep modes, affrontando l'aspetto energetico per ciascuno di essi. Il capitolo 3 conclude questa prima parte espositiva, focalizzando l'attenzione sull'importanza e il ruolo chiave che viene svolto dal machine learning per la previsione di traffico e l'ottimizzazione nei network 5G.

La seconda parte è di tipo sperimentale e presenta la simulazione del consumo energetico di una rete 5G. Vari utenti e base station vengono collocati in un'area dello spazio e vengono fatte diverse considerazioni riguardo alle prestazioni e al rendimento energetico della rete in condizioni di traffico intenso, traffico debole e una situazione in cui gli utenti vengono riallocati. Quest'ultimo caso risulta essere chiave per osservare in che modo, tramite appositi algoritmi, è possibile ridurre ulteriormente il consumo energetico della rete, pur mantenendo delle prestazioni accettabili. Viene infine visualizzato un confronto tra le varie casistiche che vengono affrontate. In particolare, verrà dimostrato come l'applicazione di un algoritmo di riallocazione consenta di ridurre il consumo energetico fino al 75%.

Indice

| | | |
|----------|--------------------------------------------------------------------------------------------------------------------|-----------|
| 1 | Introduzione | 1 |
| 2 | Efficienza energetica di una rete 5G | 5 |
| 2.1 | Il ruolo abilitante della quinta generazione (5G) | 6 |
| 2.2 | La sfida energetica del 5G | 7 |
| 2.3 | Tecnologie relative all'efficienza energetica dello standard 3GPP NR | 8 |
| 2.4 | Efficienza energetica nel mMIMO | 8 |
| 2.5 | Lean Carrier Design | 10 |
| 2.5.1 | Sleep modes | 10 |
| 3 | Il ruolo del machine learning per l'ottimizzazione dell'efficienza energetica di una rete 5G | 17 |
| 3.1 | ML per la previsione di traffico | 17 |
| 3.2 | ML per l'ottimizzazione dell'efficienza energetica nel 5G | 20 |
| 4 | Simulazione ed implementazione di algoritmi di ottimizzazione dell'efficienza energetica di una rete 5G | 25 |
| 4.1 | Descrizione dell'algoritmo e del simulatore | 26 |
| 4.2 | Parametri della simulazione | 29 |
| 4.3 | Risultati numerici | 31 |
| 5 | Conclusioni | 35 |
| | Bibliografia | 37 |

Capitolo 1

Introduzione

L'obiettivo di questa tesi è approfondire il tema dell'efficienza energetica nelle reti wireless di quinta generazione (5G), ponendo particolare attenzione alle sfide legate al consumo energetico. Le reti di quinta generazione rappresentano una soluzione innovativa nel panorama delle telecomunicazioni, offrendo prestazioni elevate in termini di velocità, latenza e capacità di connessione [1]. Tuttavia, la crescita esponenziale del numero di dispositivi connessi e l'aumento del traffico dati previsto per il futuro comportano nuove sfide [2].

Tra queste, la gestione del consumo energetico si rivela cruciale per contenere l'impatto ambientale delle infrastrutture di rete, considerando che le stazioni base (BS) rappresentano circa il 57% del consumo energetico complessivo delle reti, una percentuale che potrebbe ridursi leggermente al 50,6% entro il 2025 con l'adozione del 5G. Tuttavia, anche se le reti 5G risultano più efficienti in termini di energia per bit trasmesso, il loro consumo energetico complessivo potrebbe aumentare fino al 140% rispetto alle reti 4G, principalmente a causa della maggiore densità di stazioni base, antenne e infrastruttura cloud necessarie per supportare le nuove funzionalità [3].

Obiettivi della tesi

Questo studio si propone di indagare e analizzare diverse tecniche e soluzioni per migliorare l'efficienza energetica nelle reti 5G. In particolare, gli obiettivi principali sono:

1. Esaminare e comparare le tecnologie emergenti che possono contribuire a ridurre il consumo energetico delle reti 5G.

2. Valutare il ruolo del machine learning (ML) per ottimizzare l'efficienza energetica delle stazioni base e prevedere il traffico di rete.
3. Implementare un algoritmo di riallocazione degli utenti in grado di ottimizzare il consumo energetico di una rete 5G in condizioni di traffico debole, e valutare le prestazioni dell'algoritmo tramite simulazioni di rete.

Metodologia

Il lavoro di ricerca è strutturato in due fasi principali: una parte teorica e una sperimentale.

Nella fase teorica, vengono introdotte e descritte le tecnologie più rilevanti per l'ottimizzazione energetica nel contesto delle reti 5G. Tra queste si annoverano il massive MIMO (mMIMO), il Lean Carrier Design e le modalità di sleep, analizzate con riferimento ai loro contributi per ridurre il consumo energetico.

Nella fase sperimentale, invece, sono stati sviluppati e testati modelli di simulazione in grado di riprodurre differenti scenari di rete e valutare le performance degli algoritmi di ottimizzazione del consumo energetico. Le simulazioni includono situazioni di traffico intenso e debole, oltre ad un algoritmo in grado di riallocare gli utenti in funzione del traffico offerto, osservando l'impatto di questo tipo di algoritmi sul risparmio energetico complessivo.

Struttura della tesi

La tesi è organizzata nei seguenti capitoli:

- **Capitolo 1: Introduzione** – Descrive gli obiettivi, la metodologia, i contributi e la struttura della tesi.
- **Capitolo 2: Efficienza energetica di una rete 5G** – Fornisce un inquadramento delle tecnologie 5G e delle sfide legate al loro impatto energetico, approfondendo le principali innovazioni per l'ottimizzazione energetica.
- **Capitolo 3: Il ruolo del machine learning per l'ottimizzazione dell'efficienza energetica di una rete 5G** – Presenta i metodi di machine learning per la previsione del traffico e l'ottimizzazione del consumo energetico.
- **Capitolo 4: Simulazione ed implementazione di algoritmi di ottimizzazione dell'efficienza energetica di una rete 5G** – Descrive le spe-

cifiche dell'algoritmo e del simulatore implementati per valutare l'impatto delle tecniche proposte.

- **Capitolo 5: Conclusioni** – Riassume i risultati ottenuti e suggerisce possibili sviluppi futuri della ricerca.

La tesi rappresenta un contributo significativo nello studio dell'efficienza energetica nelle reti 5G, affrontando il tema sia dal punto di vista tecnologico che sperimentale, e proponendo soluzioni innovative per una gestione sostenibile delle future reti di comunicazione, grazie ad un algoritmo originale per la riallocazione degli utenti.

Capitolo 2

Efficienza energetica di una rete 5G

Il mondo in cui viviamo ha subito, nel corso dei secoli, diversi cambiamenti. Gli effetti più recenti si notano a partire dalla rivoluzione industriale e dall'automazione del lavoro, i quali hanno portato ad una rapida accelerazione del progresso tecnologico [4].

Uno degli impatti più significativi è stato l'aumento della produzione di CO₂, risultante dalla vasta richiesta energetica per far funzionare impianti industriali e non solo [5]. Il comparto ICT (e, nello specifico, le reti di telecomunicazione) contribuisce per una percentuale significativa alle emissioni. Ciò ha portato a un conseguente innalzamento delle temperature, dando origine al fenomeno sempre più attuale del riscaldamento globale, una minaccia per gli ecosistemi e la vita sulla Terra [6]. Basti pensare che tra il 1906 e il 2005, la temperatura del pianeta è aumentata da 0,6 a 0,9 gradi centigradi, e il tasso di aumento della temperatura è quasi raddoppiato negli ultimi 50 anni [7].

Per andare incontro a questa sfida, i governi internazionali stanno puntando ad un aumento dell'efficienza energetica e ad una svolta decisa dai combustibili fossili alle fonti di energia rinnovabile.

Le reti di nuova generazione, pur essendo progettate per rispondere alle esigenze di connettività in continua crescita, devono affrontare il problema del consumo energetico. L'aumento del numero di dispositivi connessi e della quantità di dati scambiati, unito alla pressione per ridurre le emissioni di CO₂, rende essenziale che le reti 5G siano ottimizzate per l'efficienza energetica. Nel capitolo, analizzeremo come le tecnologie e i protocolli adottati nello standard 5G siano orientati non solo a migliorare le prestazioni di rete, ma anche a ridurre al minimo l'impatto ambientale, facendo un uso più intelligente e mirato delle risorse energetiche disponibili.

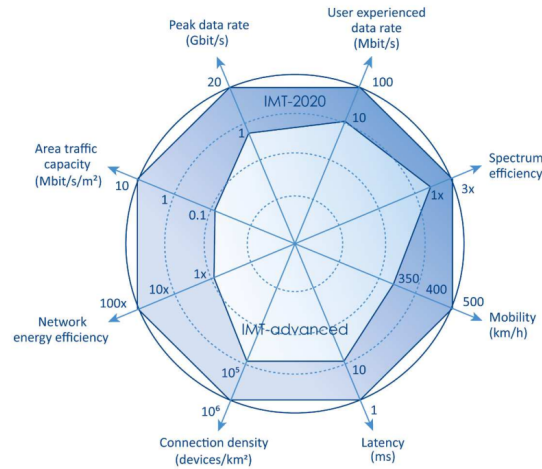


Figura 2.1: Confronto delle capacità chiave dell'IMT-Advanced (4G) con l'IMT-2020 (5G) [8].

2.1 Il ruolo abilitante della quinta generazione (5G)

Nell'ambito delle telecomunicazioni wireless la tecnologia 5G è un grande passo avanti per contrastare questo problema, migliorando il servizio per utenti e usufruttori delle reti, e allo stesso tempo riducendo l'impatto ambientale tramite intelligenti misure di efficienza energetica.

A livello macroscopico, la nuova tecnologia 5G abilita un nuovo tipo di capacità di rete in grado di connettere per la prima volta sia tutti che tutto insieme, inclusi macchine, oggetti e dispositivi, grazie alla sua maggiore capacità, minore latenza, miglior affidabilità e al numero più elevato di connessioni supportate [2].

Nella figura 2.1 vengono comparate le specifiche della quarta (4G) e quinta generazione (5G). Si può notare quanto il 5G sia migliore dei suoi predecessori su tutti i fronti.

Di conseguenza, il 5G è già diventato una parte integrante dei programmi di efficienza energetica e di riduzione del consumo, sia a livello governativo che industriale. Si prevede che un utilizzo intelligente delle risorse permetterà una significativa riduzione delle emissioni di gas serra. Tuttavia, è fondamentale evitare che, per soddisfare i requisiti stringenti in termini di latenza e data rate, le reti 5G consumino più energia delle reti 4G. È necessario trovare un equilibrio tra prestazioni e sostenibilità, implementando strategie che garantiscano un consumo energetico contenuto e l'uso efficiente delle risorse.

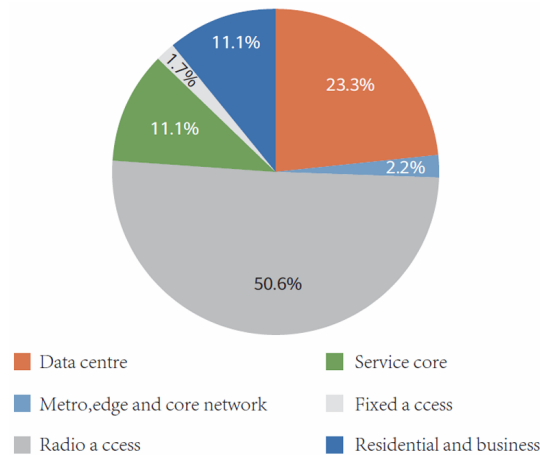


Figura 2.2: Ripartizione del consumo energetico per elemento di rete nel 2025 [10].

2.2 La sfida energetica del 5G

I vantaggi del 5G sono dunque molteplici, ma si portano dietro una questione cruciale: l'efficienza energetica. Entro il 2030 infatti, si potrebbero raggiungere i 100 miliardi di dispositivi connessi, con reti 5G che arriveranno a sostenere fino a 1000 volte il traffico delle reti 4G [9]. I *Mobile Network Operators* (MNO) dovranno gestire queste richieste e allo stesso tempo ridurre il consumo energetico. In questo contesto, i *Radio Access Network* (RAN) rappresentano la componente della rete che consuma la maggior parte dell'energia. In particolare, le stazioni base sono i principali responsabili di questo consumo energetico, essendo i nodi di accesso che collegano i dispositivi degli utenti alla rete mobile. Poiché devono gestire una grande quantità di traffico dati e fornire copertura a un numero sempre maggiore di utenti e dispositivi connessi, il loro consumo energetico è considerevole. La figura 2.2 mostra una previsione di come il consumo energetico dei vari elementi di rete sarà ripartito nel 2025.

Per migliorare l'efficienza energetica, sono stati introdotti amplificatori di potenza più efficienti, fonti di energia rinnovabile, batterie intelligenti e sistemi di raffreddamento liquido. Inoltre, dato che le stazioni base sono i maggiori consumatori, è fondamentale che siano attive solo durante la trasmissione dei dati, minimizzando i segnali "sempre attivi" [9]. Tecnologie come il massive MIMO, il Lean Carrier Design e le sleep modes aiutano a ottimizzare l'uso energetico del 5G, e il machine learning sta ulteriormente potenziando questi sforzi. Questi ultimi sono tra gli obiettivi di questo elaborato e verranno approfonditi nel corso della lettura.

2.3 Tecnologie relative all'efficienza energetica dello standard 3GPP NR

La tecnologia wireless 5G è standardizzata a livello globale tramite il 3GPP NR (3rd Generation Partnership Project New Radio) [11], sviluppato dal 3GPP, una collaborazione tra organizzazioni di telecomunicazioni e stakeholder industriali.

Lo standard 3GPP NR presenta una svolta rispetto a qualsiasi tecnologia cellulare precedente. Introduce un nuovo design fascio-centrico (*beam-centric*) che abilita un uso estensivo di *beamforming* (letteralmente “modellamento dei raggi”) e un maggiore *multiplexing* spaziale delle informazioni su una determinata risorsa tempo-frequenza [12]. Tali guadagni di *beamforming* e *multiplexing* consentono di ridurre la potenza di trasmissione per raggiungere una determinata distanza obiettivo e/o soddisfare i requisiti di rete (i.e., QoS) dell'utente finale, con conseguenti potenziali benefici in termini di mitigazione delle interferenze e risparmio energetico.

Inoltre, il 3GPP NR segue un nuovo principio di progettazione *ultra-lean*, in cui i segnali di controllo non vengono trasmessi costantemente in ogni frame radio, ma su richiesta e in modo più sporadico, in base ai requisiti di traffico. In questo modo è possibile creare un'architettura di rete più distribuita, che facilita l'implementazione del machine learning per derivare politiche operative ottimali ed efficienti dal punto di vista energetico attraverso una raccolta e un'elaborazione centralizzate dei dati.

2.4 Efficienza energetica nel mMIMO

Il mMIMO (massive Multiple-Input Multiple-Output) è forse uno degli sviluppi più importanti del 5G. Il mMIMO si riferisce ad una tecnologia dove le stazioni base sono equipaggiate con array di antenne composte da un elevato numero di elementi (≥ 100 , in alcune condizioni) [13]. In particolare, in condizioni di banda ad alte frequenze, un vasto array di antenne mMIMO può favorire ad una pluralità di sotto-spazi di canale per sostenere molteplici trasmissioni simultanee a –o ricezioni da– differenti utenti.

Nonostante offra diversi benefici, il mMIMO presenta anche delle sfide di ottimizzazione. Uno dei fenomeni chiave è la cosiddetta *pilot contamination* [14], causata dal numero limitato di *uplinks* (collegamenti) disponibili, in cui si crea interferenza tra gli utenti di celle vicine tra loro. Questa interferenza ha un

impatto sulle prestazioni del mMIMO, rendendo il riutilizzo coordinato dei *pilot* un'area critica di ricerca e ottimizzazione.

Le reti 5G si pongono l'obiettivo di raggiungere un'efficienza energetica circa 100 volte superiore a quella delle generazioni precedenti e il mMIMO viene identificato come una tecnologia chiave per raggiungere questo traguardo [8]. Tuttavia, alimentare un numero così elevato di antenne nelle base station, assieme al notevole *signal processing* (elaborazione del segnale) necessario per gestire una maggiore capacità in una cella mMIMO, porta ad un incremento del consumo energetico della stazione base [2].

Esistono dei limiti teorici che riguardano la capacità e il consumo energetico di sistemi mMIMO. Una delle sfide principali riguarda la precisione e la trattabilità dei modelli usati per caratterizzare le prestazioni a livello di rete (*network-level*). Ad esempio, interferenze tra celle differenti e/o la *pilot contamination* possono causare un peggioramento di capacità e rate, ma ciò è difficile da vedere in modelli trattabili.

Alla luce di questi problemi di trattabilità, la maggior parte delle scoperte teoriche si riferisce ai cosiddetti scenari a cella singola (*single-cell*), mentre per derivare stime di metriche e trade-off per l'efficienza energetica in scenari a cella multipla (*multiple-cell*) si ricorre a valutazioni numeriche effettuate con l'aiuto di simulatori di rete.

Scenario a cella singola (single-cell)

Riguardo ai limiti dell'efficienza energetica, degli studi iniziali hanno dimostrato che aggiungere più antenne potrebbe ridurre linearmente la potenza di trasmissione, migliorando così l'efficienza energetica [15]. Tuttavia, modelli più avanzati hanno evidenziato che anche il consumo di energia dei circuiti della BS deve essere considerato, complicando i trade-off. Si è scoperto che l'efficienza energetica si stabilizza dopo aver raggiunto un certo numero di antenne, poiché il costo energetico aggiuntivo di quest'ultime compensa i guadagni prestazionali.

Per quanto riguarda l'ottimizzazione invece, sono state derivate soluzioni per ottimizzare parametri come il numero di antenne e di utenti multiplexati. Questi studi suggeriscono che ottimizzare la densità delle stazioni base e il numero di utenti serviti può massimizzare l'efficienza energetica [16].

Scenario a cella multipla (multiple-cell)

L'efficienza energetica dei sistemi mMIMO nelle implementazioni a cella multipla è meno compresa a livello teorico, a causa della complessità nel modellare reti su larga scala. Vari fattori come la topologia, la distribuzione degli utenti e le interferenze contribuiscono a questa difficoltà.

I ricercatori hanno utilizzato la geometria stocastica per stimare le prestazioni e l'efficienza energetica, ma anche modelli semplificati mostrano che l'efficienza energetica dipende da fattori come il numero di antenne, la *pilot contamination* e le interferenze tra celle [17].

Lo scenario a cella multipla è tutt'ora uno dei fronti su cui la ricerca si sta concentrando di più, cercando di produrre modelli e risultati sempre più precisi, anche con l'aiuto del machine learning e dell'intelligenza artificiale.

2.5 Lean Carrier Design

Nelle generazioni tecnologiche precedenti, i segnali per il rilevamento delle stazioni base, per il broadcast di informazioni di sistema, e per la valutazione di canale erano sempre attivi o trasmessi molto frequentemente, indipendentemente dal fatto che le BS avessero degli utenti connessi o meno. È importante notare che, sebbene questi segnali sempre attivi facilitino le operazioni degli utenti, danno anche origine a diverse problemi come l'introduzione di molteplici risorse accessorie e di interferenza inter-cellulare (diminuendo il *throughput* raggiungibile), la diminuzione della durata delle batterie degli utenti e in generale il peggioramento dell'efficienza energetica [2].

Con il 3GPP NR sono state rivisitate la trasmissione di questi segnali di controllo e le procedure relative, seguendo un nuovo **Lean Carrier Design**: quando il carico di traffico di una cella —o di un gruppo di celle— è basso, o le condizioni di mobilità degli utenti lo permettono, si possono selezionare cicli di segnalazione più lunghi per rendere il *carrier* più leggero, ridurre l'*overhead*, mitigare le interferenze e, cosa più importante, risparmiare energia, se l'hardware della BS viene spento di conseguenza.

2.5.1 Sleep modes

Una delle introduzioni fondamentali del Lean Carrier Design è sicuramente quella delle **sleep modes**. Le reti cellulari infatti, sono spesso pianificate e realizzate per

raggiungere determinati requisiti di traffico intenso; ciò porta ad un sovradimensionamento della rete durante periodi di traffico più ridotto e ad un conseguente consumo energetico eccessivo. Le risorse sottoutilizzate delle BS potrebbero essere spente dinamicamente per risparmiare energia.

Il Lean Carrier Design permette delle fasi di micro-sleep di durata fino a 160 ms in presenza di traffico intermittente [18]. Questi tempi di sleep possono essere aumentati sfruttando delle sleep modes avanzate (*Advanced Sleep Modes, ASMs*), che permettono delle modalità di risparmio più profonde.

Nel 3GPP NR viene specificata una nuova funzionalità per attivare/disattivare piccole celle che si sovrappongono con macrocelle più vaste, ad esempio tramite messaggi di attivazione/disattivazione di celle attraverso interfacce specifiche.

Risparmio energetico nel dominio del tempo (symbol shutdown)

I meccanismi di risparmio energetico nel dominio del tempo vengono definiti **symbol shutdown**, e si riferiscono a quelle soluzioni che sono mirate a risparmiare energia considerando le variazioni del carico di traffico a breve termine in una cella. Operano nella scala temporale che va dalle centinaia di microsecondi fino alle centinaia di millisecondi, sfruttando il Lean Carrier Design introdotto dal 3GPP NR.

Cominciando da un confronto con il 3GPP LTE (4G), in quest'ultimo è possibile utilizzare la trasmissione discontinua (*discontinuous transmission, DTX*) tra celle per disattivare i componenti hardware delle BS. I benefici, però, sono limitati e questo meccanismo può raggiungere al massimo uno *sleep ratio* del 33% a carico nullo. Con l'introduzione di frame di rete a frequenza singola per multicast-broadcast (MBSFN) e la modalità FeMBMS (*further evolved multimedia broadcast multicast service*)/unicast-mixed lo *sleep ratio* aumenta fino al 93,75% [18].

Rispetto al 3GPP LTE, il 3GPP NR è caratterizzato da un tipo di segnalazione specifica per utente/dati invece di una specifica per cella. Ciò permette *sleep ratios* maggiori (fino al 99,38%) e tempi di spegnimento più lunghi (fino a 159 ms).

Il 3GPP individua 4 sleep modes:

- **Sleep mode 1**, con una durata (disattivazione più riattivazione) di 71 μ s, permette la disattivazione del PA (*power amplifier*) e di alcuni componenti della BBU (*baseband unit*) digitale e del front-end (FE) analogico.




Figura 2.3: Andamento del consumo energetico mentre la BS entra in modalità di sospensione successive [20].

- **Sleep mode 2**, con una durata minima di 1 ms, consente di spegnere ulteriori componenti del FE analogico.
- **Sleep mode 3**, con una durata minima di 10 ms, permette alla stazione base di disattivare tutti i processi della BBU digitale e quasi tutto il FE analogico (eccetto il generatore di clock).
- **Sleep mode 4**, con una durata minima di 1 secondo, mantiene attive solo le funzionalità di riattivazione.

Nei periodi di assenza di traffico, una BS può passare sequenzialmente per le varie sleep modes per ridurre il proprio consumo energetico. Questo processo viene chiamato **Advanced Sleep Mode**.

Il passaggio da una modalità ad un'altra crea latenza e può andare ad impattare la prestazione complessiva degli utenti; per far fronte a ciò, è necessario ottimizzare il “percorso” tra le varie sleep modes, e attivare preventivamente i componenti hardware delle BS prima che il traffico arrivi per evitare perdite di resa. Nella figura 2.3 viene visualizzato l'andamento della potenza media normalizzata in funzione del tempo. Man mano che la BS entra nelle sleep modes successive, il consumo diminuisce, in maniera piuttosto brusca nei primi 5 ms, per poi stabilizzarsi dopo circa 0,5 s.

Per valutare l'impatto positivo delle diverse ASM e della loro ottimizzazione sull'efficienza energetica, in [19] è stato proposto un nuovo modello di consumo energetico per le BS, ovvero,

$$P_{BS} = \begin{cases} P_{TX} + P_{CP}, & \text{if } P_{TX} > 0, \\ \delta_s P_{CP}^{li}, & \text{if } P_{TX} = 0 \text{ and sleep mode is active} \end{cases} \quad (2.1)$$

dove P_{TX} , P_{CP} , P_{CP}^{li} sono rispettivamente la potenza di trasmissione, la potenza del circuito, il consumo di potenza del circuito indipendente rispetto al carico, e δ_s la frazione del consumo di potenza del circuito indipendente rispetto al carico P_{CP}^{li} richiesta dalla cella in modalità *sleep*.

In conclusione, è importante far notare che sono stati proposti dei timer dedicati per controllare la disattivazione dei componenti e permettere delle modalità di sleep più profonde. Questi timer dipendono fortemente dal traffico presente in ogni BS, di conseguenza per sfruttare in maniera più flessibile le varie sleep modes si ricorre a modelli di machine learning, i quali sono in grado di comprendere più in profondità la struttura e il traffico all'interno delle reti.

Risparmio energetico nel dominio della frequenza (carrier shutdown)

I meccanismi di risparmio energetico nel dominio della frequenza vengono definiti carrier shutdown e si riferiscono a quelle soluzioni che sfruttano la *deep dormancy* per disattivare i componenti hardware della BS per lunghi periodi di tempo (rispetto alla soluzione a breve termine del symbol shutdown). Affrontiamo nel particolare quei meccanismi che vengono utilizzati per risparmiare energia considerando le variazioni di traffico a lungo termine di una cella.

Nella maggior parte delle celle, infatti, si nota una certa tendenza per cui durante le prime ore mattutine è presente un traffico basso, durante le ore lavorative un traffico medio e un traffico alto durante le ore di tarda serata. Inoltre, i fine settimana sono caratterizzati da un traffico meno intenso rispetto a quello generato durante i giorni lavorativi.

In questo caso le varie soluzioni operano su vaste scale temporali, quindi non vengono progettate e integrate con il Lean Carrier Design del 3GPP NR. Il 3GPP individua tre meccanismi principali di risparmio energetico nel dominio dei carrier: intra-BS, inter-BS e inter-RAT.

Meccanismi di risparmio energetico intra-BS Nel risparmio energetico di tipo intra-BS, una BS può attivare meccanismi di risparmio energetico per adattare localmente la sua capacità ai requisiti di traffico con l'obiettivo principale di ridurre il consumo energetico dell'amplificatore di radiofrequenze (RF). Ciò viene

fatto controllando dinamicamente il numero di *component carriers* (*CCs*) attivi in un sistema *multi-carrier* o *carrier aggregation* (*CA*).

Tuttavia, questi meccanismi di risparmio energetico intra-BS possono avere effetti negativi sulla rete, come riduzione della copertura e aumento del carico e delle interferenze per le BS vicine. Per ottimizzare il consumo energetico a livello di rete e garantire la QoS degli utenti, è necessario considerare questi effetti di rete durante la configurazione della BS.

Meccanismi di risparmio energetico inter-BS I meccanismi di tipo inter-BS operano su BS vicine, in maniera centralizzata o distribuita, per ottimizzare congiuntamente l'uso di risorse radio e fornire risparmi energetici senza influire significativamente sulla QoS degli utenti. Questo problema di gestione delle risorse, tuttavia, è spesso laborioso, dato che coinvolge molteplici funzionalità di rete e formulazioni matematiche complesse.

Il 3GPP NR Release 15 ha introdotto funzionalità per supportare l'attivazione e disattivazione delle celle booster di capacità (*capacity booster cells*), che sono sovrapposte a una cella di copertura più ampia. Queste celle booster possono spegnersi autonomamente in base al carico della cella, e le celle vicine vengono informate tramite interfacce specifiche.

Un altro meccanismo popolare è quello del *cell zooming*. Questo riduce la copertura di celle poco cariche, aumentando quella delle celle vicine per compensare. Un approccio basato sui dati può utilizzare un modello di previsione del traffico per gestire il *cell zooming*, portando a un risparmio energetico del 20% con un minimo aumento della probabilità di interruzione del servizio.

Meccanismi di risparmio energetico inter-RAT Nelle prime fasi delle implementazioni del 5G, le stazioni base 3GPP NR non sono distribuite uniformemente nelle aree urbane, rendendo necessaria una stretta collaborazione con la rete 3GPP LTE. Nonostante le reti 5G siano complessivamente più efficienti rispetto alle reti LTE, le BS 3GPP NR consumano più energia rispetto a quelle LTE a causa del loro hardware più complesso, che include una maggiore larghezza di banda e un numero di antenne superiore, introdotti dalla tecnologia mMIMO. Sono in fase di sviluppo soluzioni per il risparmio energetico inter-RAT per spegnere le celle booster di capacità NR quando la domanda di traffico è bassa.

Risparmio energetico nel dominio delle antenne (channel shutdown)

Un altro modo per ridurre il consumo energetico è quello di utilizzare un sottoinsieme di antenne delle stazioni base quando il carico di traffico è abbastanza basso, risparmiando energia ma allo stesso tempo mantenendo le esigenze di traffico. Questo tipo di approccio viene definito selezione di antenne o arresto di canale (*channel shutdown*).

Nei sistemi a banda larga come il 5G con molti *sub-carrier*, è improbabile che un'antenna della BS sia simultaneamente non selezionata da tutti i *sub-carrier*. Inoltre, la selezione di antenne basata su distorsione rapida multi percorso (*multi-path fast fading*) richiede che tutte le antenne delle BS siano attive almeno per la stima di canale, limitandone così il tempo di *sleep*.

Come spesso accade, mentre in sistemi a cella singola è possibile ottimizzare il consumo energetico individuando un numero di antenne da mantenere attive, in sistemi a cella multipla il problema diventa molto più complesso, soprattutto a causa delle interferenze introdotte dalla *pilot contamination* [2].

Capitolo 3

Il ruolo del machine learning per l'ottimizzazione dell'efficienza energetica di una rete 5G

L'ottimizzazione di consumo energetico dipende fortemente dalla precisione dei modelli utilizzati e, sfortunatamente, molti dei modelli attuali sono rigidi, soprattutto quelli teorici, non in grado di adattarsi alle caratteristiche di canale, alle tecnologie abilitanti, o ai cambiamenti di contesto.

Per contrastare questo problema risulta fondamentale implementare l'intelligenza artificiale (AI) e il machine learning (ML) all'interno dei modelli di ottimizzazione di consumo energetico nelle reti. In particolare, possiamo individuare tre modelli principali di ML: l'apprendimento supervisionato (*supervised learning*), l'apprendimento non-supervisionato (*unsupervised learning*) e l'apprendimento di rinforzo (*reinforcement learning*) (figura 3.1).

I modelli di apprendimento supervisionato e non-supervisionato vengono utilizzati per caratterizzare e prevedere il traffico di rete e il comportamento delle reti 5G, sfruttando vaste raccolte di dati (*data-sets*). L'essenza del *reinforcement learning* riguarda invece l'apprendimento per prendere decisioni in tempo reale attraverso interazioni con il contesto per controllare le operazioni di rete.

3.1 ML per la previsione di traffico

Una delle sfide fondamentali verso l'abilitazione di una piena adattabilità della rete ai requisiti di QoS degli utenti finali è la previsione accurata del traffico di rete. Quest'ultimo presenta infatti molteplici ostacoli:

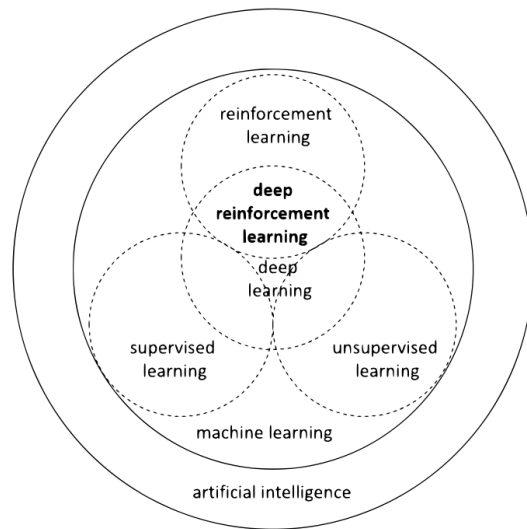


Figura 3.1: Relazioni tra deep reinforcement learning, deep learning, reinforcement learning, supervised learning, unsupervised learning, machine learning, e l'IA [27].

- gli utenti hanno diverse esigenze durante differenti momenti della giornata;
- la mobilità degli utenti introduce dipendenze spaziali tra le celle vicine;
- la distribuzione spaziale degli utenti su scala urbana è ulteriormente influenzata da vari fattori che complicano le dipendenze spazio-temporali tra le varie celle;
- la scala temporale della previsione dovrebbe corrispondere alla periodicità decisionale del meccanismo di risparmio energetico.

I vari studi hanno individuato due tipi di approccio principali per affrontare la questione, quelli basati sulla statistica e quelli basati sull'apprendimento (ML).

Metodi basati sulla statistica

Questi metodi dipendono dallo studio statistico del traffico di rete. Uno degli approcci statistici più comuni è l'ARIMA (*autoregressive integrated moving average*), la cui limitazione principale è l'incapacità di cogliere la ciclicità (*seasonality*) del traffico [21]. Per risolvere questa limitazione è stato introdotto il SARIMA (*seasonal autoregressive integrated moving average*) [22].

Tuttavia, i metodi statistici rimangono limitati in quanto non sono in grado di gestire le non-linearità e le rapide variazioni di traffico.

Metodi basati sull'apprendimento

Questi metodi sono più modellabili, in grado di gestire le non-linearità, grazie a grandi quantità di dati provenienti direttamente dalle BS. Nel seguito vengono presentati i metodi principali [2]:

- **Reti neurali ricorrenti (RNNs)**: l'esempio migliore è la *long short term memory cell* (LSTM), che risolve il *vanishing gradient problem* (problema della scomparsa del gradiente) attraverso tre porte (*input, forget* e *output*) [23]. Ulteriori miglioramenti sono stati raggiunti associando alle LSTM un modello codificatore-decodificatore che incorpora informazioni riguardanti il meteo e i periodi di vacanza per prevedere meglio il traffico di dati.

Il limite principale delle LSTM è l'incapacità di catturare le dipendenze spaziali tra le varie stazioni base. Per venire incontro a questo problema sono stati introdotti modelli ibridi composti da LSTM e auto-codificatori. Questi ultimi sono in grado di comprimere informazioni spaziali derivanti dalle celle vicine, migliorando l'accuratezza delle previsioni.

Tuttavia, questi modelli sono computazionalmente costosi e soggetti a *overfitting* a causa della loro natura completamente connessa e dell'elevato numero di parametri.

- **Reti neurali convoluzionali (CNNs)**: per risolvere i problemi delle LSTM, sono state sviluppate le LSTM convoluzionali (ConvLSTM) che sostituiscono connessioni dense con operazioni di convoluzione. Questo riduce il numero di parametri e accresce l'abilità del modello di catturare i dati spazio-temporali, rendendolo adatto a svolgere compiti di previsione di traffico, dove i dati di traffico vengono trattati come delle immagini e lo spazio geografico viene rappresentato da una matrice.

Vari esempi di queste architetture combinano le ConvLSTM con le CNN per modellare dipendenze spazio-temporali a basso e lungo raggio. In questo modo gli errori vengono ridotti fino al 61% rispetto a metodi statistici come l'ARIMA, richiedendo inoltre tempi di misurazione molto più brevi [24].

Tuttavia, una limitazione di questi approcci è che si basano su partizioni regolari a griglia, le quali non sono pratiche per le reti cellulari e possono ridurre le prestazioni delle previsioni.

- **Reti neurali a grafo (GNNs)**: questi modelli superano le limitazioni introdotte da quelli basati su partizioni regolari a griglia rappresentando

le BS come vertici di un grafo, con gli archi che definiscono le relazioni spaziali tra loro. Questo approccio modella sia il traffico generato da utenti che si muovono all'interno della copertura della BS, sia quello generato da utenti che si muovono attraverso differenti BS. Il peso di ogni arco riflette il traffico di dati tra le BS.

Per ottimizzare questi modelli, gli archi con peso più basso vengono trattati come rumore per bilanciare l'accuratezza della previsione e l'efficienza computazionale. L'errore medio assoluto (MAE) può arrivare ad essere ridotto del 16% [25].

Inoltre, la mobilità del traffico, influenzata dal movimento umano, ha un impatto significativo sull'accuratezza della previsione, rendendo i modelli utili per prevedere eventi di rete o sociali.

- **Input esterni: Punti di interesse (POIs):** la distribuzione dei punti di interesse può influenzare notevolmente la richiesta di traffico di rete. La ricerca in [26] ha individuato cinque andamenti base di traffico legati a differenti zone cittadine (residenziali, trasporti, uffici).

Uno dei punti chiave per avere una previsione di traffico più precisa è sfruttare dati provenienti da diversi domini (*domains*) e combinarli tra loro. Un modello in particolare acquisisce dati provenienti da tre gruppi differenti (posizione delle BS, distribuzione dei punti di interesse, e il livello di attività sociale), e li riunisce tutti in un'unica rappresentazione. Adottando questo modello il MAE può essere abbassato ulteriormente del 14%.

3.2 ML per l'ottimizzazione dell'efficienza energetica nel 5G

Il *reinforcement learning* (RL) e, più recentemente, il *deep reinforcement learning* (DRL) sono emersi come strumenti utili per dare inizio ad un'ottimizzazione basata sull'intelligenza artificiale all'interno di reti 5G e superiori, essendo soluzioni più leggere, flessibili e in grado di adattarsi alla dinamicità delle reti wireless.

Nel *reinforcement learning*, il processo di apprendimento è rappresentato dall'interazione fra un apprendente e un decisore, chiamato agente, e l'ambiente. L'agente seleziona delle azioni e l'ambiente risponde a queste restituendo nuo-




Figura 3.2: Il loop percezione-azione-apprendimento [2].

vi stati dell'ambiente. L'ambiente fornisce anche un valore numerico chiamato *reward* (ricompensa) che l'agente cerca di massimizzare nel tempo (figura 3.2).

Una delle principali difficoltà a cui va incontro questo approccio è la parziale osservabilità dello scenario di rete. A causa di ciò si può andare incontro al fenomeno del *temporal credit assignment problem*, in cui i vari *reward* subiscono dei ritardi, portando il sistema a reagire non sempre in maniera corretta.

L'obiettivo del RL è di imparare come mappare una situazione di cui è stata fatta esperienza con un'azione corrispondente in modo da massimizzare il *reward* numerico, tramite continue interazioni con l'ambiente.

Nel contesto dell'efficienza energetica, sono stati proposti nuovi schemi di *reinforcement learning* per gestire le modalità di risparmio energetico delle BS. In uno studio, il controllo delle *sleep modes* è stato modellato come un problema decisionale in cui la BS regola progressivamente il livello di sospensione. Quando la cella diventa inattiva, la BS entra nel livello di *sleep* più profondo e si riattiva gradualmente. Durante questo processo, la BS decide per quanti slot mantenere lo stato di sospensione. Se durante il periodo di sospensione arriva una richiesta da parte di un utente (UE), i dati vengono salvati in un *buffer* fino al risveglio della BS.

L'insieme degli stati include le possibili modalità di funzionamento della BS (inattiva, attiva o in modalità di sospensione). L'azione consiste nel decidere il numero di slot da assegnare a ciascuna modalità di sospensione. Il *reward* è definito come la somma ponderata tra il risparmio energetico ottenuto e la latenza aggiuntiva sperimentata dagli utenti a causa del *buffering*.

È stato utilizzato il popolare schema di RL chiamato Q-Learning per trovare la politica ottimale, che costruisce un'approssimazione della funzione stato-azione ottimale nel tempo. I risultati hanno mostrato che, in situazioni critiche per la latenza, la modalità di sospensione non dovrebbe essere attivata per un carico di rete superiore al 30%, mentre per carichi bassi si possono ottenere risparmi

energetici fino al 55%, anche dando priorità alla qualità del servizio degli utenti [28].

Un noto problema degli algoritmi di RL è la cosiddetta maledizione della dimensionalità (*curse of dimensionality*), che significa che i loro requisiti computazionali crescono esponenzialmente rispetto alla dimensione degli spazi degli stati e delle azioni. Per affrontare questa sfida, può essere utilizzata l'approssimazione di funzioni per approssimare la funzione di valore stato-azione quando gli spazi degli stati e/o delle azioni sono grandi o continui.

Un altro modo per gestire la maledizione della dimensionalità è l'uso di reti neurali profonde (*deep neural networks*, DNNs), essendo dei potenti approssimatori di funzioni globali. Tuttavia, la combinazioni delle DNN con il RL, ovvero il DRL, possono portare a instabilità, e addirittura divergenza durante il processo di allenamento (*training*). Per risolvere questi problemi, sono state introdotte due idee principali: l'uso del *experience replay* (un *buffer* che memorizza le esperienze passate) e una *rete target* aggiornata meno frequentemente per stabilizzare l'addestramento.

Queste migliorie hanno portato a nuove architetture DRL che affrontano problemi considerati in precedenza intrattabili. Ad esempio, un modello *deep Q-learning* (DQL) per attivare e disattivare dinamicamente le BS in base al traffico ha migliorato la stabilità e adattabilità rispetto ai metodi tradizionali.

Un altro modello DRL proposto per il controllo delle piccole celle nelle *Het-Net* dense utilizza un algoritmo *actor-critic* (figura 3.3), che seleziona le azioni e valuta le funzioni di costo, ottimizzando il consumo energetico e la latenza. Questo approccio ha dimostrato un guadagno del 30% rispetto ai modelli basati su Q-learning [29].




Figura 3.3: La struttura *actor-critic* [2].

Nonostante i progressi, restano aperte altre sfide come l'ottimizzazione distribuita tra più agenti e l'aggiornamento rapido delle politiche di apprendimento in ambienti dinamici.

Capitolo 4

Simulazione ed implementazione di algoritmi di ottimizzazione dell'efficienza energetica di una rete 5G

In questo capitolo viene presentato un esempio di simulazione di possibili scenari di rete 5G, in cui sono presenti, all'interno di una superficie confinata, degli utenti collegati a differenti stazioni base. Viene inoltre proposto e implementato un algoritmo di riallocazione, col fine di evidenziare quanto uno studio più approfondito dello scenario possa promuovere in maniera notevole il risparmio energetico all'interno di reti 5G.

La simulazione ha lo scopo di far notare gli effetti che la variazione di traffico ha sul comportamento generale della rete. In particolare, va ad analizzare in che modo cambiano i *rate* degli utenti e il consumo energetico delle celle attive. I parametri introdotti per svolgere l'analisi e simulare possibili scenari della realtà sono: il numero di utenti presenti nell'area individuata, il numero di BS attive, la percentuale di utenti attivi e l'uso o meno di un algoritmo di riallocazione.

In questo modo è possibile presentare differenti situazioni che possono verificarsi, come una maggior quantità di traffico di dati durante le ore diurne rispetto a quelle notturne, oppure le differenze di utilizzare una rete in luoghi più densamente popolati (città) rispetto a zone meno abitate (campagne).

In particolare vengono affrontati tre casi principali, ognuno dei quali ha diversi sottocasi: *i*) simulazione con il totale degli utenti attivi, *ii*) simulazione con un sottoinsieme di utenti attivi, e *iii*) simulazione con riallocazione di un sottoinsieme

di utenti attivi.

4.1 Descrizione dell'algoritmo e del simulatore

La simulazione comincia con la generazione e la disposizione (secondo un Poisson Point Process) di alcune stazioni base e 1000 utenti all'interno di un'area di 100 km².

Una volta posizionati i vari elementi, viene calcolato l'SNR (Signal-to-Noise Ratio) tra ogni utente e ogni base station nel seguente modo:

$$\text{SNR}_{\text{dB}} = \frac{P_{TX}}{PL \cdot N_0}$$

dove P_{TX} è la potenza di trasmissione (nella simulazione utilizziamo 30 dBm), N_0 è la potenza di rumore, e PL è il path loss del link.

La potenza di rumore è ottenuta dalla seguente formula (ipotizziamo un guadagno costante all'interno della rete [32]):

$$N_0 = k_B \cdot T_{eff} \cdot B$$

dove $k_B = 1,380649 \times 10^{-23}$ J K⁻¹ è la costante di Boltzmann, T_{eff} è la temperatura efficace del rumore (in condizioni standard, $T_{eff} = 290$ K), e B è la larghezza di banda (per comunicazioni a millimeter waves, in linea con le specifiche di una rete 5G, $B = 400$ MHz).

Per quanto riguarda la path loss il ragionamento è un po' più complesso. È utile far notare che all'interno di scenari reali, in particolare in quelli di tipo urbano, sono molto spesso presenti ostacoli che modificano e attenuano l'intensità del segnale trasmesso.

Come descritto in [30] modelliamo la path loss introducendo due tipi di probabilità: P_{LOS} , probabilità LOS (Line of Sight) e P_{NLOS} , probabilità NLOS (Non Line of Sight), rispettivamente riferite al caso in cui non sono presenti ostacoli tra trasmettitore e ricevitore (LOS) e a quello in cui sono presenti ostacoli (NLOS).

Per il modello Millimeter Waves le due probabilità, in funzione della distanza d , sono:

$$P_{\text{LOS}}(d) = e^{-a_{\text{LOS}}d}$$

$$P_{\text{NLOS}}(d) = 1 - P_{\text{LOS}}(d)$$

con $a_{LOS} = 0.0149 \text{ m}^{-1}$. La path loss è dunque definita nel seguente modo:

$$\begin{cases} PL_{LOS}(d) = 61.4 + 21 \log_{10}(d) + \xi_{\sigma_L}, \\ PL_{NLOS}(d) = 72 + 2.92 \log_{10}(d) + \xi_{\sigma_N}; \end{cases}$$

dove $\xi_{\sigma_L} \sim N(0, \sigma_L^2)$ e $\xi_{\sigma_N} \sim N(0, \sigma_N^2)$ caratterizzano lo *shadowing* (in dB) nelle condizioni di LOS e NLOS, rispettivamente, con $\sigma_L = 5,8 \text{ dB}$ e $\sigma_N = 8,7 \text{ dB}$ a 28 GHz.

Il passo successivo consiste nel collegare ogni UE alla BS con SNR maggiore. Questo procedimento viene definito fase di *attachment* e permette inoltre di calcolare il carico N_C di ogni stazione base, ovvero il numero totale di utenti connessi a quella cella specifica.

Una volta completata la fase di attachment, è possibile calcolare il *rate* nominale, i.e., la capacità, di ogni utente, secondo la formula di Shannon:

$$R_{\text{utente}} = \frac{B}{N_C} \cdot \log_2\left(1 + 10^{\frac{\text{SNR}}{10}}\right)$$

Nell'ultimo step viene calcolato il consumo energetico complessivo delle celle, utilizzando il seguente modello energetico. Per una singola cella, il totale è dato dalla somma di due contributi fondamentali: un consumo che viene definito "statico", intrinseco alla BS e dovuto alle sue componenti hardware ed alla circuiteria, e indipendente dal carico della cella stessa, e una componente variabile, definita consumo "dinamico", che invece dipende dal numero di utenti connessi alla stazione base. Una volta che abbiamo il consumo totale di ogni cella sommiamo i singoli contributi per ottenere il consumo energetico totale dello scenario simulato.

Simulazione con un sottoinsieme di utenti attivi

Nella seconda parte della simulazione, l'idea è quella di riprodurre uno scenario di traffico meno intenso, che si può verificare nelle ore notturne della giornata, oppure durante i fine settimana (quando la richiesta lavorativa è inferiore). Per fare ciò scegliamo di spegnere una parte degli utenti, e quindi lasciare attivo un sottoinsieme di utenti all'interno della rete.

Una volta selezionati gli utenti attivi, viene ripetuto il procedimento di *attachment*, che permette di ricalcolare il carico di ogni cella. Per il consumo energetico e il *rate* i calcoli sono gli stessi fatti in precedenza.

Simulazione con riallocazione di un sottoinsieme di utenti attivi

L'ultima parte della simulazione è quella più strettamente legata all'aspetto energetico e all'importanza dell'ottimizzazione per massimizzare l'efficienza energetica delle reti 5G.

Il punto di partenza è sempre il caso in cui è attivo solo un subset di utenti, con la differenza che questa volta viene implementato anche un algoritmo di riallocazione. Nel seguito viene presentata l'idea alla base della riallocazione.

La funzione `riallocazione` riceve in input 4 parametri:

- l'array `carico_celle` che contiene il carico di ogni BS;
- l'array `attachment` che contiene per ogni posizione i la BS a cui è collegato l' i -esimo utente;
- la matrice `SNR_matrix` che contiene l'SNR di ogni utente verso ogni possibile BS;
- la variabile `min_rate` che contiene il *rate* minimo accettabile durante la riallocazione degli utenti.

L'algoritmo agisce nella seguente maniera:

- le celle vengono ordinate in maniera crescente in base al loro carico;
- a partire dalla cella con carico minore, si cerca di svuotarla trasferendo ogni utente della cella alle celle più vicine (selezionando l'SNR più alto);
- ogni utente che cerca di essere riallocato può essere spostato solamente all'interno di celle disponibili (alcune potrebbe essere spente), e la nuova cella deve soddisfare il requisito di *rate* minimo definito da `min_rate`;
- se per almeno un utente il requisito non è soddisfatto, il tentativo di svuotamento viene abbandonato e si passa alla cella successiva;
- se tutti gli utenti vengono riallocati, la BS di partenza viene etichettata come "vuota", e si passa alla cella successiva;
- una volta analizzate tutte le celle l'algoritmo termina, restituendo un nuovo array con gli *attachment* aggiornati; da ciò è possibile ricavare il nuovo carico (e relativo consumo energetico) di ogni BS.

4.2 Parametri della simulazione

Avendo a disposizione il simulatore, per osservare in che maniera l'ottimizzazione influenza la capacità di canale e il consumo energetico, è necessario eseguire il codice adottando un approccio di simulazione Monte Carlo in modo da variare i risultati e confrontare i possibili scenari che possono verificarsi in situazioni reali. In questo specifico caso, la simulazione subisce 90 iterazioni, una per ogni possibile combinazione dei parametri.

In questa fase risulta utile variare diversi parametri tra un'iterazione e un'altra. I parametri che consideriamo in questa esperienza sono:

- **numero di BS:** dal caso minimo di 2 stazioni base arriviamo al caso in cui sono presenti 20 celle, in modo da evidenziare l'aumento del *rate* degli utenti, ma allo stesso tempo il maggiore consumo energetico all'interno dell'area in cui sono collocate;
- **percentuale di UE attivi:** in base al numero di utenti attivi contemporaneamente abbiamo la possibilità di emulare diversi momenti della giornata e della settimana, alternando periodi di traffico meno intenso a periodi in cui la quantità di dati trasmessi si avvicina al picco di carico massimo. Su 1000 UE totali “accendiamo” dei sottoinsiemi (in maniera casuale) a partire dal 5% fino a raggiungere la totalità di utenti attivi;
- **rate minimo:** questo parametro riguarda nello specifico l'algoritmo di riallocazione e ha lo scopo di limitare lo svuotamento delle celle imponendo una soglia minima di prestazioni di rete (in termini di data *rate*) che dev'essere rispettata per ogni utente. In questa simulazione imponiamo tre *rate* minimi: 1 Mbps, 50 Mbps, 100 Mbps e osserviamo in che modo questo vincolo influenza la riallocazione dei vari utenti e il conseguente risparmio energetico che possiamo raggiungere.

Parametri del consumo energetico

Per calcolare il consumo energetico delle base station definiamo tre tipi di consumo:

- **consumo “scarico”:** è il consumo “statico” definito in precedenza; la BS consuma energia solo per il fatto di essere accesa. Dall'analisi svolta in [3] il consumo medio di una BS 5G risulta essere l'89% di 400 W (consumo medio di una cella 4G, figura 4.2);

- **consumo idle**: fa riferimento al consumo di una cella svuotata da tutti gli utenti; quest'ultima non si spegne completamente, ma grazie alle sleep modes consuma una potenza media di 50 W (figura 4.1);
- **consumo “carico”**: è il consumo complessivo della cella dato dalla somma del consumo “scarico” e del consumo “dinamico” definito in precedenza, che dipende dal carico di ogni cella. Il consumo “dinamico” viene calcolato moltiplicando il carico per la potenza di trasmissione di ogni utente ($30 \text{ dBm} = 1 \text{ W}$).

Il consumo energetico presente nella simulazione fa riferimento ad una finestra temporale di 24 ore.




Figura 4.1: Esempio di consumo energetico teorico di una BS in modalità idle in LTE (in alto) e NR (in basso) [31].




Figura 4.2: Confronto del consumo energetico in modalità idle di LTE e NR per un prodotto radio Ericsson dual-band [31].

| Numero di BS | Utenti attivi | Rate minimo |
|--------------|---------------|-------------|
| 2 | 5% | 1 Mbps |
| 4 | 10% | 50 Mbps |
| 7 | 25% | 100 Mbps |
| 12 | 40% | |
| 20 | 50% | |
| | 60% | |

Tabella 4.1: Tabella riassuntiva dei parametri utilizzati.

4.3 Risultati numerici

In questa sezione ci occupiamo di analizzare e confrontare i risultati ottenuti dalle varie simulazioni. Consideriamo separatamente il consumo energetico e la capacità (*rate*) media ottenuti al variare del numero di BS, della percentuale di utenti attivi e del *rate* minimo per la riallocazione.

Consumo energetico

Per quanto riguarda il consumo energetico, l'andamento osservato in tutti i grafici risulta pressoché lineare: all'incremento del numero di base station corrisponde un aumento del consumo di energia. Tale incremento si verifica anche in relazione alla percentuale di utenti attivi e al valore del *rate* minimo tollerato per l'applicazione dell'algoritmo di riallocazione.

Sebbene l'andamento sia simile tra i vari scenari, è fondamentale evidenziare l'impatto significativo dell'algoritmo di riallocazione sul risparmio energetico ottenibile nella rete. Dai risultati emerge chiaramente il ruolo delle BS nel consumo energetico di una rete 5G. Limitando l'analisi al caso di 20 BS attive, si osserva che, senza l'algoritmo di riallocazione, il consumo si attesta intorno ai 200 kWh giornalieri (figura 4.3), riducendosi a circa 175 kWh a prescindere dalla percentuale di utenti attivati (figura 4.4). L'applicazione dell'algoritmo di riallocazione consente invece di raggiungere un minimo di circa 45 kWh giornalieri, tollerando un *rate* minimo di 1 Mbps (figura 4.5), il che rappresenta un risparmio energetico pari al 75%.

Infine, si nota come per ottenere prestazioni più elevate (*rate* di 50 Mbps e 100 Mbps, figure 4.6, 4.7) sia necessario un maggiore consumo energetico, con l'aumento del numero di utenti attivi che incide sensibilmente sulle possibilità di risparmio.

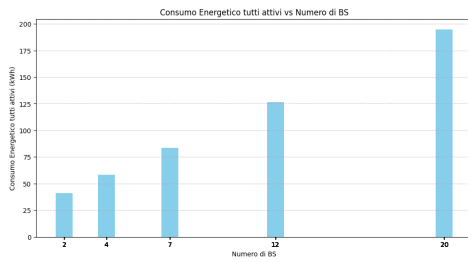


Figura 4.3

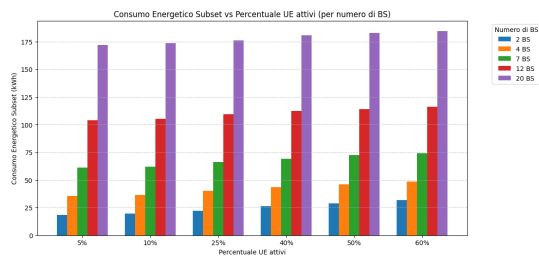


Figura 4.4

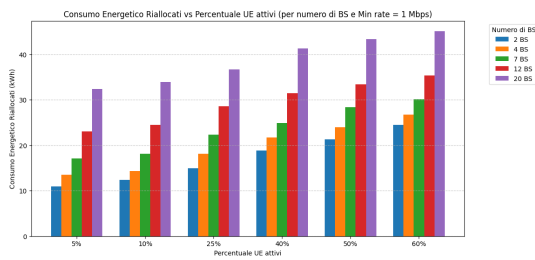


Figura 4.5

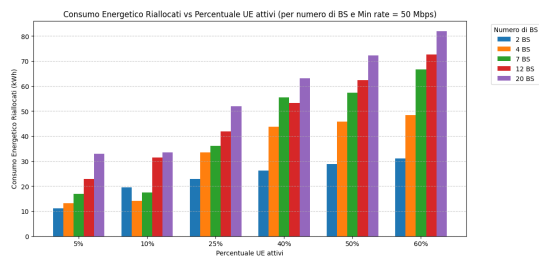


Figura 4.6

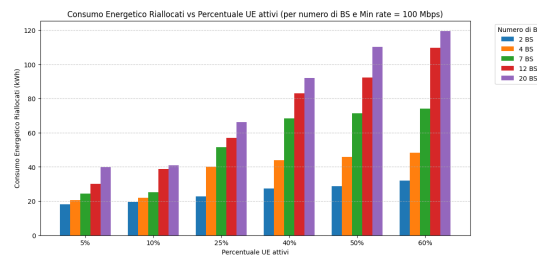


Figura 4.7

Capacità media

Concentrando l'analisi sul *rate* (capacità) medio, si osserva che, senza riallocazione, la dipendenza dal numero di BS è anch'essa lineare e l'impatto del numero di utenti attivi è rilevante. Considerando il caso con 20 BS, il *rate* medio si attesta intorno a 140 Mbps con tutti gli utenti attivi (figura 4.8), mentre con il 5% di utenti attivi aumenta fino a quasi 3 Gbps (figura 4.9), ovvero circa 1000 volte superiore rispetto al caso in cui è attiva la totalità degli utenti.

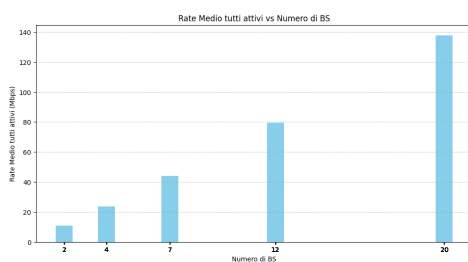


Figura 4.8

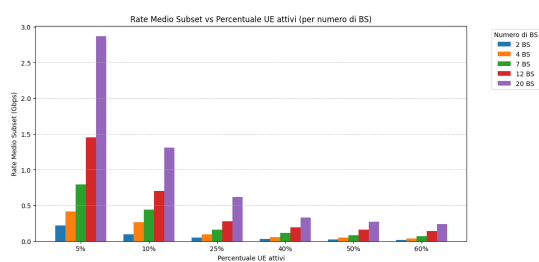


Figura 4.9

La situazione con riallocazione appare più complessa da interpretare. Mentre negli scenari precedenti l'andamento era relativamente uniforme, in questo caso i risultati mostrano una distribuzione più irregolare. All'aumentare del numero di utenti attivi, il *rate* medio tende a diminuire, ma questo comportamento non è sempre direttamente correlato al numero di BS attive. Possiamo fare un paio di considerazioni a riguardo:

- In figura 4.10, considerando il caso con il 5% di utenti attivi, si osserva come il *rate* medio sia simile sia con 2 BS che con 20 BS. Tale comportamento è attribuibile al fatto che la simulazione è stata eseguita una sola volta con parametri prestabiliti, e poiché la posizione degli utenti, così come il loro stato attivo/inattivo, è casuale, può verificarsi che la riallocazione avvenga in modo casuale, coinvolgendo un numero variabile di celle. Lo stesso fenomeno si manifesta anche nel caso del 10% di utenti attivi (sempre in figura 4.10) e nei casi 5% e 10% nelle figure 4.11 e 4.12.

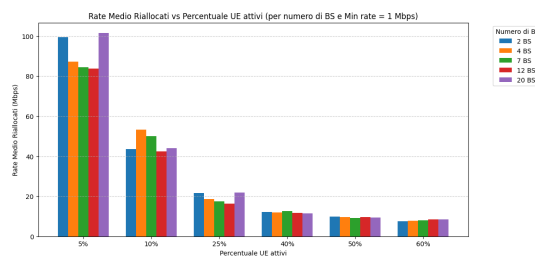


Figura 4.10

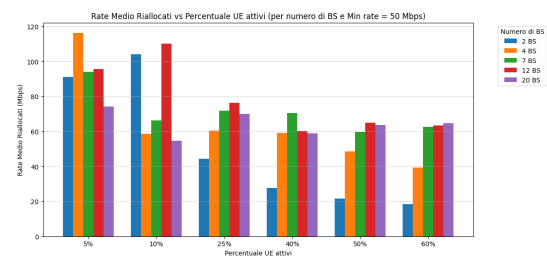


Figura 4.11




Figura 4.12

- Un altro andamento rilevante si riscontra nelle situazioni con una percentuale di utenti attivi dal 25% in poi, nelle figure 4.10, 4.11 e 4.12. Questo fenomeno è particolarmente evidente in figura 4.10, dove il *rate* medio rimane invariato nonostante le variazioni sia nel numero di utenti attivi, sia nel numero di BS operative. Con un *rate* minimo impostato a 1 Mbps, la riallocazione risulta particolarmente efficace e, indipendentemente dal numero

di utenti attivi, il numero di BS attive rimane pressoché costante. Tuttavia, per *rate* minimi più elevati (si veda figura 4.11 e figura 4.12), si nota come talvolta la riallocazione fallisca (il *rate* medio risulta inferiore al *rate* minimo) e, tra le 12 BS e le 20 BS, il *rate* si stabilizzi a causa del vincolo imposto dal risparmio energetico, mantenendo attivo un numero minimo tollerato di BS. Questa osservazione evidenzia l'impatto della riduzione del consumo energetico sul *rate* effettivamente disponibile per gli utenti.

Capitolo 5

Conclusioni

Sintesi dei risultati e contributi della ricerca

Questo lavoro di tesi ha approfondito l'analisi delle reti wireless 5G, con particolare attenzione all'ottimizzazione dell'efficienza energetica tramite l'implementazione di tecnologie e algoritmi avanzati. Dopo una panoramica delle principali innovazioni tecnologiche del 5G, come il massive MIMO, il Lean Carrier Design e l'uso dei sleep modes, è stato esplorato il potenziale del machine learning per migliorare le performance di rete. Infine, sono stati progettati, implementati e testati diversi scenari di simulazione per quantificare l'impatto dell'algoritmo di riallocazione proposto, che ha dimostrato un miglioramento fino al 75% nel risparmio energetico rispetto alla configurazione senza riallocazione.

Considerazioni sui risultati numerici

I risultati delle simulazioni hanno evidenziato come l'adozione di un algoritmo di riallocazione consenta un'efficace riduzione del consumo energetico, grazie alla possibilità di spegnere in modo selettivo le base station in condizioni di traffico debole. In particolare, è emerso che:

- In scenari con il 5% di utenti attivi e 20 base station, l'algoritmo di riallocazione ha portato a una riduzione del consumo giornaliero fino a 45 kWh, un risultato notevole rispetto ai circa 175-200 kWh registrati nei casi senza riallocazione.
- Tuttavia, per garantire un *rate* minimo più elevato, l'efficacia dell'algoritmo diminuisce e il risparmio energetico si riduce. Aumentare il *rate* minimo a 50 Mbps o 100 Mbps ha portato, infatti, a un incremento del consumo energetico necessario per garantire prestazioni di rete accettabili.

La capacità media, invece, ha evidenziato una dipendenza marcata dal numero di utenti attivi e dal numero di base station operative, con una complessità crescente per il caso di riallocazione. Questa complessità indica che una distribuzione ottimale degli utenti potrebbe non sempre essere garantita a causa delle variabili di SNR e del *rate* minimo richiesto.

Limiti della ricerca e sfide aperte

Sebbene l'algoritmo di riallocazione proposto rappresenti un passo avanti verso reti più efficienti, permangono alcune sfide. L'ottimizzazione dell'efficienza energetica è un problema multidimensionale in cui intervengono diversi fattori, quali il numero di antenne, l'allocazione dello spettro e il consumo energetico dei singoli componenti delle base station. Inoltre, la gestione delle fluttuazioni di carico dovute a variazioni nel numero di utenti attivi richiede modelli predittivi più accurati e algoritmi di adattamento dinamico che possano reagire in tempo reale alle condizioni di rete. Un limite rilevante emerso riguarda la variabilità nelle prestazioni dell'algoritmo di riallocazione, che può non riuscire a riallocare efficacemente gli utenti in alcune configurazioni.

Prospettive future

Per il futuro, l'integrazione di modelli di deep learning avanzati per l'ottimizzazione delle reti 5G potrebbe offrire soluzioni dinamiche e adattative, in grado di migliorare sia l'efficienza energetica che la qualità del servizio. Le reti neurali convoluzionali (CNN) e le reti neurali a grafo (GNN) potrebbero rappresentare un ulteriore potenziamento, specialmente in contesti ad alta densità come le aree urbane. Inoltre, l'implementazione di sistemi di controllo distribuiti tra più base station, utilizzando approcci di multi-agente per gestire l'interazione tra le celle vicine, potrebbe permettere un'ottimizzazione energetica più flessibile e capillare.

Bibliografia

- [1] Maulani, Isma & Johansyah, Citra. (2023). The Development of 5G Technology and Its Implications For The Industry. *Devotion Journal of Community Service*. 4. 631-635. 10.36418/devotion.v4i2.416.
- [2] Lopez-Perez, D., de Domenico, A., Piovesan, N., Bao, H., Xinli, G., Qitao, S., & Debbah, M. (2021). "A Survey on 5G Radio Access Network Energy Efficiency: Massive MIMO, Lean Carrier Design, Sleep Modes, and Machine Learning".
- [3] M. Usama and M. Erol-Kantarci, "A Survey on Recent Trends and Open Issues in Energy Efficiency of 5G," *Sensors (Basel)*, vol. 19, no. 14, Jul. 2019.
- [4] J. Rifkin, *The Third Industrial Revolution: How Lateral Power Is Transforming Energy, the Economy, and the World*, 1st ed. St. Martin's Press, Sep. 2011.
- [5] United Nations Environment Programme, "UN Emissions Gap Report 2019," *Tech. Rep.*, Nov. 2019. [Online]. Available: <https://wedocs.unep.org/bitstream/handle/20.500.11822/30797/EGR2019.pdf>
- [6] T. F. Stocker et al., "Climate Change 2013. The Physical Science Basis. Working Group I Contribution to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change - Abstract for decision-makers," *Tech. Rep.*, Oct. 2013. [Online]. Available: <https://www.osti.gov/etdeweb/biblio/22221318>
- [7] NASA Goddard Institute for Space Studies, GISTEMP Team, "GISS Surface Temperature Analysis (GISTEMP), version 4," Available at data.giss.nasa.gov/gistemp/ (2020/10/27).

- [8] I.-R. M.2083, “Framework and overall objectives of the future development of IMT for 2020 and beyond,” Tech. Rep., Sep. 2015. [Online]. Available: <https://www.itu.int/rec/R-REC-M.2083>
- [9] Huawei Technologies Co., Ltd., “Green 5G: Building a sustainable world,” Tech. Rep., Aug. 2020. [Online]. Available: <https://www.huawei.com/en/public-policy/green-5g-building-a-sustainable-world>
- [10] J. Lorincz, A. Capone, and J. Wu, “Greener, Energy-Efficient and Sustainable Networks: State-Of-The-Art and New Trends,” *Sensors (Basel)*, vol. 19, no. 22, Nov. 2019.
- [11] 3GPP TS 38.300
- [12] M. Polese, M. Giordani, M. Zorzi, “3GPP NR: the cellular standard for 5G networks”, 5G-ITALY White Book, 2018.
- [13] T. L. Marzetta, “Noncooperative Cellular Wireless with Unlimited Numbers of Base Station Antennas,” *IEEE Transactions on Wireless Communications*, vol. 9, no. 11, pp. 3590–3600, 2010.
- [14] J. Jose, A. Ashikhmin, T. L. Marzetta, and S. Vishwanath, “Pilot Contamination and Precoding in Multi-Cell TDD Systems,” *IEEE Transactions on Wireless Communications*, vol. 10, no. 8, pp. 2640–2651, 2011.
- [15] H. Q. Ngo, E. G. Larsson, and T. L. Marzetta, “Energy and spectral efficiency of very large multiuser mimo systems,” *IEEE Transactions on Communications*, vol. 61, no. 4, pp. 1436–1449, 2013.
- [16] E. Björnson, L. Sanguinetti, J. Hoydis, and M. Debbah, “Optimal design of energy-efficient multi-user mimo systems: Is massive mimo the answer?” *IEEE Transactions on Wireless Communications*, vol. 14, no. 6, pp. 3059–3075, 2015.
- [17] T. Bai and R. W. Heath, “Analyzing uplink sinr and rate in massive mimo systems using stochastic geometry,” *IEEE Transactions on Communications*, vol. 64, no. 11, pp. 4592–4606, 2016.
- [18] 3GPP TSG RAN, “TR 37.910, Study on new radio access technology: Radio access architecture and interfaces,” V14.0.0, Mar. 2017.

- [19] S. Tombaz, P. Frenger, M. Olsson, and A. Nilsson, "Energy performance of 5g-nx radio access at country level," in 2016 IEEE 12th International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob), 2016, pp. 1–6.
- [20] B. Debaillie, C. Desset, and F. Louagie, "A flexible and future-proof power model for cellular base stations," in IEEE 81st Vehicular Technology Conference (VTC Spring), 2015, pp. 1–7.
- [21] D. L. Jagerman, B. Melamed, and W. Willinger, "Stochastic modeling of traffic processes," *Frontiers in queueing*, pp. 271–370, 1997.
- [22] R. J. Hyndman and G. Athanasopoulos, *Forecasting: principles and practice*. OTexts, 2018.
- [23] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural computation*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [24] C. Zhang and P. Patras, "Long-term mobile traffic forecasting using deep spatio-temporal neural networks," in *Proceedings of the Eighteenth ACM International Symposium on Mobile Ad Hoc Networking and Computing*. New York, NY, USA: Association for Computing Machinery, 2018, p. 231–240. [Online]. Available: <https://doi.org/10.1145/3209582.3209606>
- [25] X. Wang, Z. Zhou, F. Xiao, K. Xing, Z. Yang, Y. Liu, and C. Peng, "Spatio-temporal analysis and prediction of cellular traffic in metropolis," *IEEE Transactions on Mobile Computing*, vol. 18, no. 9, pp. 2190–2202, 2019.
- [26] F. Xu, Y. Li, H. Wang, P. Zhang, and D. Jin, "Understanding mobile traffic patterns of large scale cellular towers in urban environment," *IEEE/ACM Transactions on Networking*, vol. 25, no. 2, pp. 1147–1161, 2017
- [27] Y. Li, "Deep Reinforcement Learning," *CoRR*, vol. abs/1810.06339, Oct. 2018. [Online]. Available: <http://arxiv.org/abs/1810.06339>
- [28] F. E. Salem, T. Chahed, Z. Altman, and A. Gati, "Traffic-aware Advanced Sleep Modes management in 5G networks," in 2019 IEEE Wireless Communications and Networking Conference (WCNC), 2019, pp. 1–6.
- [29] J. Ye and Y. J. A. Zhang, "Drag: Deep reinforcement learning based base station activation in heterogeneous networks," *IEEE Transactions on Mobile Computing*, vol. 19, no. 9, pp. 2076–2087, 2020.

- [30] Giordani, M., Zanella, A., Higuchi, T., Altintas, O., & Zorzi, M. (2018). “Performance Study of LTE and mmWave in Vehicle-to-Network Communications”.
- [31] “5G energy consumption: what’s the impact of 5G NR in real networks?”, <https://www.ericsson.com/en/blog/2021/10/5g-energy-consumption-impact-5g-nr>
- [32] Benvenuto, N., & Zorzi, M. (2011). Principles of Communications Networks and Systems. John Wiley & Sons Ltd.