

Configuração Adaptativa de C-DRX Baseada em Perfis de Tráfego para Eficiência Energética em Redes 5G

Tiago Souza Garcia de Lima Filho e Lidiano Augusto Nóbrega de Oliveira

Resumo—As redes 5G suportam uma ampla diversidade de serviços com requisitos heterogêneos de taxa de dados, latência e confiabilidade. Nesse contexto, a eficiência energética dos equipamentos de usuário torna-se um desafio crítico, especialmente para dispositivos alimentados por bateria. Este artigo apresenta uma estratégia de configuração de Recepção Descontínua no modo Conectado (*Connected Mode Discontinuous Reception – C-DRX*) sensível ao tráfego para as redes 5G, que adapta ciclos e temporizadores dinamicamente, usando informações multi-camada e classificação de perfis em janelas de observação. Foi utilizado aprendizado de máquina para distinguir perfis de tráfego que combinam taxa e sensibilidade à latência e aplicar políticas de C-DRX. As simulações mostraram que o classificador obtém alta acurácia e que a proposta reduz o consumo de energia sem comprometer a latência e o QoS.

Palavras-Chave—Rede 5G, C-DRX, Eficiência Energética, Perfil de Tráfego, QoS, Aprendizado de Máquina.

Abstract—5G networks support a wide diversity of services with heterogeneous data rate, latency, and reliability requirements. In this context, the energy efficiency of user equipment becomes a critical challenge, especially for battery-powered devices. This paper presents a traffic-aware Connected Mode Discontinuous Reception (C-DRX) configuration strategy for 5G networks, which dynamically adapts cycles and timers using multi-layer information and profile classification within observation windows. Machine learning was used to distinguish traffic profiles that combine data rate and latency sensitivity, and to apply C-DRX policies. Simulations showed that the classifier achieves high accuracy and that the proposal reduces energy consumption without compromising latency and QoS.

Keywords—5G Network, C-DRX, Energy Efficiency, Traffic Profile, QoS, Machine Learning.

I. INTRODUÇÃO

As redes móveis de quinta geração (5G) introduzem um paradigma de provisão flexível de serviços, permitindo o atendimento conjunto de diferentes classes de tráfego, como em cenários eMBB (*Enhanced Mobile Broadband*), mMTC (*massive Machine-Type Communications*) e URLLC (*Ultra-Reliable Low-Latency Communication*) [1]. Essa heterogeneidade implica padrões de tráfego muito distintos: fluxos contínuos ou quase contínuos em eMBB (vídeo 4K, realidade aumentada), transmissões esparsas em mMTC (sensores, atuadores), e pequenas cargas com forte requisito de latência em URLLC (controle industrial, aplicações críticas).

Do ponto de vista do usuário final e de diversos cenários de aplicação da Internet das Coisas (IoT), a autonomia da

bateria é um requisito crucial. Equipamentos de Usuário (*User Equipments – UEs*) com capacidade de operar por dias (como *smartphones*) ou até anos (sensores IoT) sem recarga são essenciais, o que torna a eficiência energética na interface aérea um objetivo fundamental das redes 5G. Entre os mecanismos de conservação de energia, a recepção descontínua (*Discontinuous Reception – DRX*) destaca-se como uma técnica-chave, permitindo que o UE desligue periodicamente seu receptor para reduzir o consumo de potência.

Nas redes 5G NR, o DRX foi estendido e flexibilizado em relação ao LTE (*Long Term Evolution*) por meio da Recepção Descontínua no modo Conectado (*Connected Mode Discontinuous Reception – C-DRX*), oferecendo maior capacidade de ajuste de temporizadores e ciclos [2]. Apesar disso, a maior parte das implementações práticas ainda adota perfis de C-DRX relativamente estáticos ou pouco adaptados à diversidade de perfis de tráfego [3]. Considerando que o comportamento temporal do tráfego pode variar significativamente ao longo do tempo e entre aplicações, configurações estáticas tendem a resultar em um compromisso subótimo entre economia de energia e desempenho (latência, *jitter*, perda de pacotes) [4].

Neste artigo é apresentada uma estratégia adaptativa de configuração de C-DRX em redes 5G NR baseada no perfil de tráfego observado. A proposta integra técnicas de aprendizado de máquina ao ajuste dinâmico dos temporizadores de C-DRX, utilizando características temporais extraídas do tráfego para identificar diferentes classes de serviço com requisitos distintos de taxa e latência. Além disso, é realizada uma análise da robustez da abordagem frente a variações estatísticas do tráfego, demonstrando ganhos significativos de eficiência energética com impacto controlado na latência e na QoS.

O restante do artigo está organizado da seguinte forma: a Seção II apresenta os trabalhos relacionados; as Seções III e IV descrevem o C-DRX e a estratégia proposta; a Seção V detalha a metodologia; a Seção VI apresenta os resultados e a Seção VII contém as conclusões.

II. ESTADO DA ARTE

A otimização da eficiência energética em redes celulares consolidou-se no ecossistema LTE por meio do mecanismo C-DRX. Conforme levantamento realizado em [5], as abordagens pioneiras focaram na modelagem matemática do compromisso entre a taxa de hibernação do dispositivo e o atraso no *downlink*. Nesse cenário, o trabalho em [6] utilizou teoria de filas e estatísticas de tráfego para avaliar o desempenho sob perfis homogêneos (como navegação *web* e VoIP).

Com a introdução do 5G NR (*New Radio*) e de novos requisitos de serviços (eMBB, mMTC, URLLC), os documentos de especificação do 3GPP (*3rd Generation Partnership Project*) passaram a oferecer maior flexibilidade de configuração de C-DRX, incluindo ciclos curtos e longos e timers diferenciados [7]. Estudos recentes exploram C-DRX em cenários 5G heterogêneos, avaliando impactos em eficiência energética [8] e QoS [9] para diferentes categorias de serviço. Entretanto esses trabalhos não propõem um mecanismo ou algoritmo autônomo para entender o perfil de tráfego em tempo real e ajustar dinamicamente os parâmetros de C-DRX.

Para superar as limitações das abordagens estáticas, estudos recentes propõem configurações sensíveis ao tráfego. Essas soluções integram algoritmos de aprendizado de máquina e inferência preditiva diretamente ao agendador da estação radiobase. Estratégias como as otimizações de C-DRX propostas em [10] e a estrutura de aprendizado profundo Deep-DRX [11] permitem identificar o comportamento temporal e adaptar dinamicamente a duração e a alternância entre ciclos curtos e longos do C-DRX. No entanto, essas soluções não incorporam explicitamente a latência na classificação do perfil, aspecto considerado neste trabalho.

A partir das modificações na própria arquitetura do C-DRX, viabilizadas por meio de recursos avançados introduzidos no Release 16 do 3GPP [7], abordagens recentes utilizam modelos estatísticos de tráfego e aprendizado de máquina para refinar a configuração do C-DRX. Em soluções baseadas em modelos ON/OFF [12] ou de Poisson [13], parâmetros estatísticos alimentam formulações de otimização sob restrições de latência. Uma estratégia baseada em aprendizado por reforço profundo foi explorada em [14], empregando o algoritmo de aprendizado. Porém, esse método limitou-se ao ajuste do comprimento do ciclo e apenas dois cenários restritos, nos quais o tráfego seguia distribuições com taxas médias fixas.

Apesar dos avanços, permanece uma lacuna para abordagens que considerem explicitamente o perfil de tráfego de cada serviço. Este trabalho se insere nesse contexto, combinando estatísticas de tráfego e técnicas de aprendizado de máquina para configuração adaptativa do C-DRX.

III. MECANISMOS DO C-DRX

O procedimento de C-DRX foi introduzido para reduzir o consumo de energia dos terminais em estado conectado. O princípio básico do C-DRX consiste em alternar dinamicamente o estado do UE entre os estados ativo e de hibernação (sleep) sem comprometer a recepção de dados e o controle de retransmissões.

A janela temporal em que o UE deve obrigatoriamente monitorar o canal físico de controle de *downlink* (*Physical Downlink Control Channel* – PDCCH) é definida pelo conceito de Tempo Ativo. A base desse ciclo é determinada pelo *drx-onDurationTimer*, que define a quantidade de subquadros ou milissegundos consecutivos no início de cada ciclo de C-DRX em que o receptor de RF deve permanecer ligado. Como ilustrado na Fig. 1, caso nenhum dado seja endereçado ao UE durante o *onDuration* até o término do temporizador, ele retorna imediatamente ao estado de hibernação, completando o ciclo e mantendo o receptor de RF desligado pelo restante do período correspondente ao ciclo de C-DRX.




Fig. 1. Mecanismo C-DRX.

Caso decodifique uma nova concessão no PDCCH, o UE adia o retorno à hibernação ao disparar o *drx-InactivityTimer*. Esse temporizador define o período consecutivo de monitoramento após cada pacote recebido, reiniciando a cada nova decodificação para evitar o desligamento dos circuitos de RF durante rajadas intermitentes de tráfego.

A configuração de C-DRX é realizada através de parâmetros sinalizados pela gNodeB, incluindo:

- Temporizador de Inatividade (*drx-InactivityTimer*): determina por quanto tempo, após a recepção ou transmissão de dados especificados em uma concessão no PDCCH, o UE permanece em modo de recepção contínua antes de entrar em C-DRX.
- Temporizador de Período Ativo (*drx-onDurationTimer*): janela de tempo dentro de um ciclo C-DRX em que o UE desperta para monitorar o PDCCH.
- Ciclo C-DRX (curto e longo): O ciclo de C-DRX define o período de repetição do mecanismo, em que ciclos curtos (*drx-ShortCycle*) associados ao contador de repetições (*drx-ShortCycleTimer*) reduzem a latência e aumentam o consumo de energia, enquanto ciclos longos (*drx-LongCycleStartOffset*) produzem o efeito oposto. O ciclo curto opera como uma fase de transição opcional antes do UE migrar definitivamente para o ciclo longo.

O consumo energético diminui com o aumento do tempo que o UE esteja hibernando, enquanto a latência para entrega de pacotes *downlink* tende a aumentar, especialmente no primeiro pacote após um período de inatividade. O dimensionamento adequado desses parâmetros é, portanto, um problema clássico de compromisso entre eficiência energética e desempenho.

A. C-DRX no contexto dos serviços 5G

As categorias eMBB, mMTC e URLLC apresentam requisitos distintos. Aplicações mMTC favorecem ciclos longos de C-DRX para maior economia de energia, enquanto aplicações eMBB e URLLC podem demandar ciclos menores para atender aos requisitos de latência.

IV. CONFIGURAÇÃO DO C-DRX SENSÍVEL AO TRÁFEGO

Configurações estáticas de C-DRX, definidas apenas por perfis genéricos de serviço ou por parâmetros pré-configurados, ignoram informações valiosas sobre o comportamento real do tráfego. A ideia central de C-DRX sensível

ao tráfego é que as configurações de C-DRX sejam ajustadas com base em padrões históricos de tráfego, tipo de aplicação, requisitos de QoS e contexto temporal de uso.

A. Caracterização dos Perfis de Tráfego

Seguindo a abordagem de classificação de tráfego em 5G apresentada em [15], o comportamento do tráfego é sintetizado em classes analisadas experimentalmente em [15], destacando:

- BT-BL (Baixa Taxa, Baixa Latência) – Aplicações que demandam baixa taxa de transmissão, com pacotes de pequeno tamanho e tempo de chegada entre os pacotes relativamente estável, representando, por exemplo, voz sobre IP e jogos interativos leves. Foram considerados processos de chegada com baixa taxa média de transmissão e tamanhos de pacotes inferiores aos observados nos perfis AT-BL e AT-AL.
- AT-BL (Alta Taxa, Baixa Latência) – Tráfego caracterizado por uma alta taxa de transmissão com comportamento aproximadamente contínuo em *uplink* e *downlink*, representando videochamadas. Os processos de chegada para *uplink* e *downlink* foram configurados com taxas elevadas e pequenas variações entre o tempo de chegada dos pacotes, enquanto os tamanhos de pacotes apresentaram valores intermediários em relação aos demais perfis.
- AT-AL (Alta Taxa, Alta Latência) – Tráfego em rajadas com longos períodos de ociosidade, representando *streaming* de vídeo bufferizado e navegação *web*. Nesse caso foi adotado um modelo do tipo ON/OFF, no qual períodos ON contêm rajadas de pacotes de grande tamanho e alta taxa de transmissão em comparação aos demais perfis analisados, seguidos de períodos OFF com poucas ou nenhuma chegada.

V. METODOLOGIA DE SIMULAÇÃO E CLASSIFICAÇÃO DE TRÁFEGO

Nesta seção é descrita a metodologia adotada para implementação em Python de um simulador de tráfego e do classificador correspondente, utilizado para identificar perfis de tráfego a partir de dados sintéticos. O objetivo é reproduzir o fluxo de classificação e adaptação, considerando que as estatísticas de tráfego podem ser obtidas no UE e utilizadas pela rede para selecionar a configuração de C-DRX. A classificação não busca identificar a aplicação, mas inferir seu comportamento temporal e sua sensibilidade à latência a partir do tráfego observado.

A. Geração de Tráfego Sintético

A primeira etapa consistiu no desenvolvimento de geradores de tráfego IP, específicos para cada classe de interesse: BT-BL, AT-BL e AT-AL. Com base nos perfis de tráfego em [15], foram definidos modelos sintéticos representativos das três classes. Para BT-BL, foram utilizados pacotes de 200 bytes, com intervalo médio entre chegadas de 20 ms; para AT-BL, pacotes de 1000 bytes e intervalo médio de 2 ms; e, para AT-AL, adotou-se um modelo ON/OFF, com períodos ON e OFF médios de 2 s e 5 s, respectivamente, pacotes de 1400 bytes e intervalo médio entre chegadas de 2 ms durante o período ON.

Para cada classe, o simulador gerou uma sequência temporal de eventos na forma (t_i, s_i, d_i) , onde t_i é o instante de chegada do pacote i , s_i é o seu tamanho em bytes, e $d_i \in \{\text{UL}, \text{DL}\}$ indica a direção (*uplink* ou *downlink*). O tempo total de simulação por classe é escolhido de modo a produzir um volume suficiente de janelas temporais para treinamento e teste do classificador.

B. Extração de Características em Janelas de Observação

A partir dos traços sintéticos, foi implementada uma rotina de extração de características (*features*) baseada em janelas deslizantes de observação. O tempo contínuo é discretizado em intervalos elementares de duração $\Delta t = 0,5$ s. Em cada intervalo de tempo são computadas dez estatísticas independentes para *uplink* e *downlink*, compreendendo o número total de pacotes, o tempo entre chegadas (médio e máximo) e as dimensões dos pacotes (valores médio, mínimo e máximo).

Para classificação, foi utilizada uma janela deslizante de observação com duração $T_{\text{obs}} = 3$ s, composta por seis intervalos de 0,5 s. Cada janela gerou uma matriz 6×10 , em que as linhas representam os intervalos de tempo e as colunas as estatísticas calculadas, sendo rotulada conforme a classe de tráfego correspondente (BT-BL, AT-BL ou AT-AL).

C. Treinamento do Classificador

O classificador utilizou uma técnica de aprendizado de máquina baseada no algoritmo XGBoost (*Extreme Gradient Boosting*), que apresentou um melhor desempenho em termos de acurácia e eficiência computacional em relação aos outros algoritmos investigados. O modelo recebeu, como entrada, o vetor de características associado a cada janela de 3 s e produz, como saída, uma predição da classe de tráfego.

O treinamento é realizado de forma supervisionada, buscando minimizar uma função de perda apropriada para classificação multiclasse, como a entropia cruzada. O XGBoost foi configurado com 150 árvores, profundidade máxima 4 e taxa de aprendizado 0,05. Na análise de sensibilidade, foram avaliadas 100–250 árvores, profundidades de 3–6 e taxas de aprendizado de 0,03–0,10, observando-se baixa variação na acurácia.

D. Ambiente de Simulação e Validação dos Parâmetros

Para avaliar a metodologia proposta, os perfis de tráfego identificados pelo modelo de Machine Learning e as configurações dinâmicas de C-DRX foram validados em um simulador de rede em nível de sistema, implementado em Python. Esse simulador modela múltiplos UEs conectados a uma gNodeB e reproduz as máquinas de estados e temporizadores de C-DRX definidos pelo 3GPP, conforme a Figura 1.

O fluxo de dados no ambiente de simulação é estruturado em três etapas principais:

- Geração de Tráfego Heterogêneo – O simulador gera rajadas de pacotes baseando-se em modelos estocásticos, que refletem o comportamento das classes de serviços.
- Atuação do Classificador – Em janelas de observação periódicas, as estatísticas de tráfego são injetadas no modelo de Aprendizagem de Máquina. O classificador

infe o perfil de tráfego e define o vetor de parâmetros ideais (*drx-onDurationTimer*, *drx-InactivityTimer* e *drx-LongCycleStartOffset*).

- Execução do Procedimento de C-DRX – O simulador processa a chegada do pacote na fila de rádio. Caso uma concessão no PDCCH ocorra durante o *onDuration*, o temporizador de inatividade é disparado. Quando a fila está vazia e os temporizadores expiram, o simulador calcula o tempo em que o receptor do UE ficou desligado.

Como métricas de desempenho para os testes de validação, o simulador contabiliza:

- Fração de Economia de Energia – A razão entre o tempo total em que o UE permaneceu em estado de hibernação e o tempo total da simulação.
- Atraso Adicional – A latência introduzida quando um pacote chega à gNodeB no momento em que o UE está em hibernação, exigindo que o pacote aguarde na fila até o próximo período de despertar.
- Taxa de Queda de QoS – a porcentagem de pacotes que violaram o limiar de latência exigido por cada serviço.

O simulador em Python permite contrapor a parametrização estática com a proposta adaptativa, mapeando o compromisso entre preservação de bateria e latência de rede. O modelo energético considera os estados de recepção do UE, não incluindo o custo computacional da classificação.

VI. RESULTADOS

Para avaliar o impacto da adaptação de C-DRX baseada em perfis de tráfego, foram comparadas três estratégias. A primeira é o C-DRX fixo, que consiste em uma configuração estática definida pela rede com *drx-Cycle* = 80 ms e *drx-InactivityTimer* = 40 ms para todos os UEs. A segunda abordagem é o C-DRX adaptativo por taxa, cujo ajuste baseia-se apenas na estimativa da taxa de transmissão sem classificação de perfil, adotando ciclos curtos para baixa vazão e ciclos longos para alta taxa de dados, sem considerar a sensibilidade à latência. Por fim, a terceira estratégia proposta, que é o C-DRX adaptativo por perfil, realizando o ajuste dinâmico com base nas classes BT-BL, AT-BL e AT-AL.

A acurácia global para o classificador foi de aproximadamente 96,5%, com as taxas específicas de acerto por classe indicadas na Tabela I.

TABELA I
PERCENTUAL DE JANELAS ROTULADAS CORRETAMENTE.

Tipo	Janelas Rotuladas Corretamente (%)
BT-BL	97,8
AT-BL	95,9
AT-AL	95,7

O consumo médio de energia relativo para cada classe de perfil é apresentado na Figura 2, com valores normalizados pela estratégia de C-DRX fixo. Os dados correspondem a um cenário equivalente a 30 minutos de tráfego por classe.

O comportamento do atraso nos cenários mais desfavoráveis é apresentado na Figura 3, que quantifica a latência, normalizada em relação a estratégia de C-DRX Fixo, no 98º percentil por classe de perfil. O uso dessa métrica estatística garante




Fig. 2. Consumo médio de energia por classe.

que 98% do tráfego simulado experimentou um atraso igual ou inferior ao demonstrado, permitindo avaliar com precisão o impacto das janelas de hibernação do C-DRX sobre os limites estritos de QoS das aplicações.




Fig. 3. Latência por classe de perfil.

Foi analisada a distribuição do tempo do UE em diferentes estados de consumo (ativo, sono leve e sono profundo). A Figura 4 apresenta, para as três classes de tráfego, a fração de tempo em cada estado sob C-DRX fixo e sob C-DRX adaptativo por perfil.




Fig. 4. Fração de tempo em estados ativo, hibernação leve e profunda.

A análise dos estados do dispositivo revela comportamentos

distintos entre as classes de tráfego. No cenário BT-BL, a estratégia proposta eleva o tempo em sono profundo em cerca de 35%, reduzindo drasticamente o monitoramento do canal de controle. Essa dinâmica é mais moderada na classe AT-BL, que apresenta apenas um leve incremento no sono leve devido à natureza quase contínua do tráfego. Por fim, na classe AT-AL, a adoção de ciclos de C-DRX mais longos viabiliza um deslocamento expressivo do estado ativo para o sono profundo durante os períodos OFF do tráfego, consolidando a eficiência energética do sistema.

Por fim, foi avaliada a robustez da solução frente à variação de parâmetros de tráfego não vistos explicitamente no treinamento do classificador. Para isso, foram gerados cenários com:

- Variações de até $\pm 20\%$ na taxa média de chegada de pacotes por classe;
- Alterações moderadas nas distribuições de tamanho de pacotes;
- Padrões ON/OFF com durações de períodos ON e OFF ligeiramente diferentes dos utilizados na fase de treinamento.

A Figura 5 apresenta a acurácia do classificador e o ganho energético médio do C-DRX adaptativo por perfil sob essas variações. A acurácia global permanece acima de 93% em todos os cenários testados, e a redução média de energia, em relação ao C-DRX fixo, varia no intervalo de 17% a 35%, indicando que a abordagem mantém ganhos significativos mesmo quando o tráfego desvia dos modelos sintéticos empregados.




Fig. 5. Acurácia do classificador e redução média de energia sob variação de parâmetros de tráfego.

Os resultados indicam que a classificação de tráfego em perfis, aliada a uma política de configuração de C-DRX sensível a esses perfis, permite obter ganhos energéticos significativos com impacto controlado na latência, mesmo em cenários com incerteza moderada sobre o padrão de tráfego subjacente.

VII. CONCLUSÕES

Explorando informações sobre padrões de tráfego, tipos de aplicação e contexto de uso, foi possível adaptar os parâmetros de C-DRX (como ciclos e temporizadores) de forma dinâmica, obtendo ganhos significativos de economia de energia no UE, especialmente em cenários mMTC e eMBB.

Os resultados obtidos no cenário simulado indicam a eficácia da metodologia frente ao C-DRX fixo, reduzindo o consumo de energia em todas as classes de tráfego com impacto

controlado na latência. Esse desempenho superior fundamenta-se na otimização dos estados do dispositivo: o tempo em hibernação aumentou significativamente em cenários de baixa taxa ou com períodos de silêncio, mitigando o desperdício com o monitoramento do canal de controle, enquanto o algoritmo agiu de forma conservadora diante de tráfegos contínuos.

Como trabalho futuro, planeja-se integrar o Channel Quality Indicator (CQI) às métricas de contexto, permitindo antecipar degradações de canal e retransmissões que afetam a latência fim-a-fim. Além disso, pretende-se validar a abordagem utilizando datasets públicos e traços de tráfego reais, ampliando a representação da variabilidade encontrada em redes 5G e complementando os modelos sintéticos empregados neste estudo.

REFERÊNCIAS

- [1] L. A. N. Oliveira, M. S. Alencar, and W. T. A. Lopes, "Evolução da Arquitetura de Redes Móveis Rumo ao 5G," *Revista de Tecnologia da Informação e Comunicação*, vol. 8, no. 2, pp. 43–50, 2018.
- [2] M. K. Maheshwari, E. Rastogi, A. Roy, N. Saxena, and D. R. Shin, "DRX in NR Unlicensed for B5G Wireless: Modeling and Analysis," *IEEE Transactions on Mobile Computing*, vol. 22, no. 9, pp. 5184–5197, 2023.
- [3] N. Accurso, N. Mastronarde, and F. Malandra, "Modelling and Optimization of DRX in Cellular IoT Networks: an MDP Approach," in *ICC 2023 - IEEE International Conference on Communications*, pp. 6169–6174, 2023.
- [4] J.-H. Yu, Y.-J. Choi, H.-Y. Jeong, J.-E. Kim, and H.-K. Song, "Enhancement of C-DRX Efficiency with Traffic Prediction Using Ensemble Learning Models," in *2025 Sixteenth International Conference on Ubiquitous and Future Networks (ICUFN)*, pp. 678–682, 2025.
- [5] K.-H. Lin, H.-H. Liu, K.-H. Hu, A. Huang, and H.-Y. Wei, "A Survey on DRX Mechanism: Device Power Saving From LTE and 5G New Radio to 6G Communication Systems," *IEEE Communications Surveys & Tutorials*, vol. 25, no. 1, pp. 156–183, 2023.
- [6] C. S. Bontu and E. Illidge, "DRX Mechanism for Power Saving in LTE," *IEEE Communications Magazine*, vol. 47, no. 6, pp. 48–55, 2009.
- [7] 3GPP, "Technical Specification Group Radio Access Network; Medium Access Control (MAC); Protocol Specification," Technical Specification (TS) 38.321, 3rd Generation Partnership Project (3GPP), March 2026. Version 18.9.0.
- [8] Y.-N. R. Li, M. Chen, J. Xu, L. Tian, and K. Huang, "Power Saving Techniques for 5G and Beyond," *IEEE Access*, vol. 8, pp. 108675–108690, 2020.
- [9] S. C. Sundararaju, M. Balasubramaniam, and D. Das, "Novel C-DRX Mechanism for Multi SIM Multi Standby UEs in 5G and B5G Networks," in *2020 IEEE 3rd 5G World Forum (5GWF)*, pp. 318–323, 2020.
- [10] P. Bruhn and G. Bassi, "Machine Learning Based C-DRX Configuration Optimization for 5G," in *Mobile Communication - Technologies and Applications; 25th ITG-Symposium*, pp. 1–6, 2021.
- [11] M. L. Memon, M. K. Maheshwari, D. R. Shin, A. Roy, and N. Saxena, "Deep-DRX: A Framework for Deep Learning-Based Discontinuous Reception in 5G Wireless Networks," *Transactions on Emerging Telecommunications Technologies*, vol. 30, no. 3, p. e3579, 2019. e3579.
- [12] M. M. Sallam, F. W. Zaki, M. M. Ashour, and H. B. Nafea, "Performance Enhancement of DRX Sleep Mode Based on Signaling/Paging Traffic Arrival in 5G Communication Systems," *Alexandria Engineering Journal*, vol. 120, pp. 318–348, 2025.
- [13] B. Cai, Y. Chen, and I. Darwazeh, "Analyzing Energy Efficiency for IoT Devices with DRX Capability and Poisson Arrivals," in *2019 26th International Conference on Telecommunications (ICT)*, pp. 254–259, 2019.
- [14] J. Zhou, G. Feng, T.-S. P. Yum, and S. Qin, "Actor-critic algorithm based discontinuous reception (drx) for machine-type communications," in *2018 IEEE Global Communications Conference (GLOBECOM)*, pp. 1–7, 2018.
- [15] A. Ali, Y. Heng, V. Va, P. Parida, B. L. Ng, and J. C. Zhang, "UE Power Saving With Traffic Classification and UE Assistance," *IEEE Access*, vol. 11, pp. 136869–136884, 2023.