



SAUS, Quadra 6, Bloco H, 10º Andar, Ala Sul - Bairro Asa Sul, Brasília/DF, CEP 70070-940
Telefone: (61) 2312-2003 - <https://www.gov.br/anatel>

TERMO DE EXECUÇÃO DESCENTRALIZADA Nº 4/2024

Processo nº 53500.060216/2024-35

Unidade Gestora: Superintendência de Outorga e Recursos a Prestação

DADOS CADASTRAIS DA UNIDADE DESCENTRALIZADORA

Unidade Descentralizadora e Responsável

Nome do órgão ou entidade descentralizador(a): Agência Nacional de Telecomunicações (ANATEL).

Nome das autoridades competentes:

- CARLOS MANUEL BAIGORRI - Presidente da Anatel - CPF:***.573.***-35
- ALEXANDRE REIS SIQUEIRA FREIRE- Conselheiro da Anatel - CPF:***.851.***-53

Identificação dos Atos que conferem poderes para assinatura:

- Decreto s/nº, de 13 de abril de 2022, publicado no Diário Oficial da União (DOU), Seção 2, Extra B, página 1, do dia 13/04/2022;
- Decreto s/nº, de 29 de novembro de 2022, publicado no Diário Oficial da União (DOU), seção 2, página 1, do dia 30/11/2022.

UG SIAFI

Número e Nome da Unidade Gestora - UG que descentralizará o crédito: 413001 - Anatel Sede;

Número e Nome da Secretaria/Departamento/Unidade Responsável pelo acompanhamento da execução do objeto do TED: 413066 - Superintendência de Outorga e Recursos a Prestação

DADOS CADASTRAIS DA UNIDADE DESCENTRALIZADA

Unidade Descentralizada e Responsável

Nome do órgão ou entidade descentralizada: Universidade Federal do Rio de Janeiro

Nome das autoridades competentes:

- Roberto de Andrade Medronho - Reitor da Universidade Federal do Rio de Janeiro - CPF: ***.401.***-49

Identificação dos Atos que conferem poderes para assinatura:

- Decreto de 27 de junho de 2023, publicado no DOU nº 121, de 28 de junho de 2023

UG SIAFI

Número e Nome da Unidade Gestora - UG que receberá o crédito: 153115 - UNIVERSIDADE FEDERAL DO RIO DE JANEIRO

Número e Nome da Secretaria/Departamento/Unidade Responsável pela execução do objeto do TED: 15236 - UNIVERSIDADE FEDERAL DO RIO DE JANEIRO

OBJETO DO TERMO DE EXECUÇÃO DESCENTRALIZADA

Esta proposta aborda a aplicação de técnicas de Inteligência Artificial (IA) na gestão do espectro radioelétrico, com foco no planejamento e em seu uso eficiente. O espectro é um recurso escasso e valioso para sistemas de comunicação, sendo fundamental para tecnologias como 5G, 6G, e IoT. Através da adoção de métodos avançados de IA, são propostas ferramentas que permitam a previsão da demanda futura de espectro, a alocação dinâmica e adaptativa, e o monitoramento contínuo, otimizando o uso das frequências disponíveis.

As metas do projeto incluem a análise de abordagens de IA já utilizadas ou com potencial de utilização na gestão do espectro, a avaliação da utilização da IA nas tarefas do regulador e a elaboração de um plano de ação para a implantação de soluções de IA para a gestão do espectro. O projeto avalia o impacto da aplicação de IA no cenário regulatório brasileiro, propondo um roteiro de ações de curto, médio e longo prazo para que reguladores e operadoras de telecomunicações possam adotar essas soluções de forma eficaz.

A primeira meta foca o levantamento das tecnologias IA voltadas para a comunicação por rádio, especificamente nos contextos de 5G e 6G. Métodos como aprendizado de máquina supervisionado e não supervisionado, aprendizado por reforço, além de redes neurais artificiais, serão investigados para identificar sua aplicabilidade na gestão de espectro. As técnicas permitirão o desenvolvimento de sistemas inteligentes e adaptativos, capazes de gerenciar o espectro de maneira eficiente e sustentável.

A segunda meta explora o uso de IA para melhorar a previsibilidade e o controle do espectro, por meio de simulações e modelos de propagação baseados em dados. Essas simulações serão utilizadas para prever interferências, otimizar a alocação de frequências e melhorar a eficiência geral do espectro.

A terceira meta busca orientar reguladores na adoção de IA, propondo diretrizes para a implementação dessas soluções no contexto regulatório. Através do desenvolvimento de protótipos, treinamentos e workshops, o projeto visa capacitar os profissionais envolvidos, garantindo a correta implementação e operação de ferramentas de IA para a gestão de espectro.

Finalmente, o projeto oferece uma análise do impacto econômico e regulatório da adoção dessas tecnologias, estimando o retorno sobre o investimento e propondo estratégias para garantir a sustentabilidade e a conformidade com as normas vigentes.

Em resumo, este projeto tem como objetivo transformar a gestão do espectro através da IA, garantindo o uso eficiente de frequências em redes complexas e promovendo um planejamento mais dinâmico e adaptativo.

OBRIGAÇÕES E COMPETÊNCIAS DOS PARTÍCIPES

4.1. Unidade Descentralizadora:

- I - analisar e aprovar a descentralização de créditos;
- II - analisar, aprovar e acompanhar a execução do Plano de Trabalho;
- III - descentralizar os créditos orçamentários;

- IV - repassar os recursos financeiros em conformidade com o cronograma de desembolso;
- V - aprovar a prorrogação da vigência do TED ou realizar sua prorrogação, de ofício, quando necessário;
- VI - aprovar as alterações no TED;
- VII - solicitar Relatórios parciais de Cumprimento do Objeto ou outros documentos necessários à comprovação da execução do objeto, quando necessário;
- VIII - analisar e manifestar-se sobre o Relatório de Cumprimento do Objeto apresentado pela Unidade Descentralizada;
- IX - solicitar à Unidade Descentralizada que instaure a tomada de contas especial, ou promover diretamente a instauração, quando cabível;
- X - emitir certificado de disponibilidade orçamentária;
- XI - registrar no SIAFI o TED e os aditivos, mantendo atualizada a execução até a conclusão;
- XII - prorrogar de ofício a vigência do TED quando ocorrer atraso na liberação de recursos, limitado ao prazo do atraso;
- XIII - publicar os extratos do TED e termos aditivos no sítio eletrônico oficial, bem como disponibilizar a íntegra do TED celebrado e do Plano de Trabalho atualizado, no prazo de vinte dias, contado da data da assinatura;
- XIV - designar os agentes públicos federais que atuarão como gestores titulares e suplentes do TED, no prazo de vinte dias, contado da data da celebração do TED, devendo o ato de designação ser publicado no sítio eletrônico oficial;
- XV - instaurar tomada de contas especial, quando cabível e a Unidade Descentralizada não o tenha feito no prazo para tanto; e
- XVI - suspender as descentralizações, na hipótese de verificação de indícios de irregularidades durante a execução do TED, com a tomada das providências previstas no art. 19 do Decreto nº 10.426/2020.

4.2. Unidade Descentralizada:

- I - elaborar e apresentar o Plano de Trabalho;
- II - apresentar a Declaração de Capacidade Técnica necessária à execução do objeto;
- III - apresentar a Declaração de Compatibilidade de Custos;
- IV - executar os créditos orçamentários descentralizados e os recursos financeiros recebidos;
- V - aprovar as alterações no TED;
- VI - encaminhar à Unidade Descentralizadora: a) Relatórios parciais de Cumprimento do Objeto, quando solicitado; e b) o Relatório final de Cumprimento do Objeto;
- VII - zelar pela aplicação regular dos recursos recebidos e assegurar a conformidade dos documentos, das informações e dos demonstrativos de natureza contábil, financeira, orçamentária e operacional;
- VIII - citar a Unidade Descentralizadora quando divulgar dados, resultados e publicações referentes ao objeto do TED, quando necessário;
- IX - instaurar tomada de contas especial, quando necessário, e dar conhecimento dos fatos à Unidade Descentralizadora;
- X - devolver à Unidade Descentralizadora os saldos dos créditos orçamentários descentralizados e não empenhados e os recursos financeiros não utilizados, conforme disposto no § 1º do art. 7º do Decreto nº 10.426, de 16 de julho de 2020;
- XI - devolver os créditos orçamentários e os recursos financeiros após o encerramento do TED ou da conclusão da execução do objeto, conforme disposto no § 2º do art. 7º do Decreto nº 10.426, de 2020;
- XII - disponibilizar no sítio eletrônico oficial a íntegra do TED celebrado e do Plano de Trabalho atualizado, no prazo de vinte dias, contado da data da assinatura;
- XIII - devolver para a Unidade Descentralizadora os rendimentos de aplicação financeira auferidos em parcerias celebradas com recursos do TED, nas hipóteses de restituição previstas na legislação específica;
- XIV - designar os agentes públicos federais que atuarão como gestores titulares e suplentes do TED, no prazo de vinte dias, contado da data da celebração do TED, devendo o ato de designação ser publicado no sítio eletrônico oficial;
- XV - disponibilizar, mediante solicitação, documentos comprobatórios da aplicação regular dos recursos aos órgãos de controle e à unidade descentralizadora;
- XVI - Não compartilhar dados ou informações obtidas ou produzidas a partir do presente Termo com terceiros sem a prévia e expressa anuência da Anatel;
- XVII - Observar o anexo II ao presente TED, relativo a dados pessoais que sejam objeto de tratamento durante e após a vigência da descentralização.

VIGÊNCIA

O prazo de vigência deste Termo de Execução Descentralizada será de 30 (trinta) meses, contados a partir da data de sua assinatura, podendo ser prorrogado de acordo com o disposto no art. 10 do Decreto nº 10.426, de 2020.

VALOR DO TED

O valor do presente termo é de R\$ 999.800,34 (novecentos e noventa e nove mil e oitocentos reais e trinta e quatro centavos).

CLASSIFICAÇÃO FUNCIONAL PROGRAMÁTICA:

24.722.2205.20ZD.0001, Atividade de Simplificação e Melhoria da Regulação, Natureza de Despesa 339039.

BENS REMANESCENTES

O Objeto do Termo de Execução Descentralizada contempla a aquisição, produção ou construção de bens?

Sim

Não

DAS ALTERAÇÕES

Ficam os partícipes facultados a alterar o presente Termo de Execução Descentralizada ou o respectivo Plano de Trabalho, mediante termo aditivo, vedada a alteração do objeto aprovado.

As alterações no plano de trabalho que não impliquem alterações do valor global e da vigência do TED poderão ser realizadas por meio de apostila ao termo original, sem necessidade de celebração de termo aditivo, desde que não envolvam o objeto aprovado e sejam previamente aprovados pelas Unidades Descentralizadora e Descentralizada.

DA AVALIAÇÃO DOS RESULTADOS

A Unidade Descentralizada apresentará relatório de cumprimento do objeto, conforme previsto no art. 23 do decreto nº 10.426, de 2020, cuja análise ocorrerá pela Unidade Descentralizadora, nos termos do art. 24 do mesmo normativo.

Rejeitado total ou parcialmente o relatório de cumprimento do objeto pela Unidade Descentralizadora, deverá a Unidade Descentralizada instaurar tomada de contas especial para apurar eventuais danos ao erário e respectivos responsáveis para fins de recomposição do erário público.

DA DENÚNCIA OU RESCISÃO

Denúncia

O Termo de Execução Descentralizada poderá ser denunciado a qualquer tempo, hipótese em que os partícipes ficarão responsáveis somente pelas obrigações pactuadas e auferirão as vantagens do período em que participaram voluntariamente do TED.

Rescisão

Constituem motivos para rescisão do presente TED:

- I - o inadimplemento de qualquer das cláusulas pactuadas;
- II - a constatação, a qualquer tempo, de irregularidades na execução do TED;
- III - a verificação de circunstâncias que ensejem a instauração de tomada de contas especial; ou
- IV - a ocorrência de caso fortuito ou de força maior que, mediante comprovação, impeça a execução do objeto.

SOLUÇÃO DE CONFLITO

Para dirimir quaisquer questões de natureza jurídica oriundas do presente Termo, os partícipes comprometem-se a solicitar o auxílio da Câmara de Conciliação e Arbitragem da Administração Federal da Advocacia-Geral da União - CCAF/AGU.

PUBLICAÇÃO

O TED e seus eventuais termos aditivos, que impliquem em alteração de valor ou, ainda, ampliação ou redução de prazo para execução do objeto, serão assinados pelos partícipes e seus extratos serão publicados no sítio eletrônico oficial da Unidade Descentralizadora, no prazo de vinte dias, contado da data da assinatura, conforme disposto no art. 14 do Decreto nº 10.426, de 2020.

As Unidades Descentralizadora e Descentralizada disponibilizarão a íntegra do TED celebrado e do Plano de Trabalho atualizado em seus sítios eletrônicos oficiais no prazo a que se refere o caput.



Documento assinado eletronicamente por **Carlos Manuel Baigorri, Presidente**, em 05/12/2024, às 20:03, conforme horário oficial de Brasília, com fundamento no art. 23, inciso II, da [Portaria nº 912/2017](#) da Anatel.



Documento assinado eletronicamente por **Alexandre Reis Siqueira Freire, Conselheiro**, em 05/12/2024, às 20:10, conforme horário oficial de Brasília, com fundamento no art. 23, inciso II, da [Portaria nº 912/2017](#) da Anatel.



Documento assinado eletronicamente por **Roberto de Andrade Medronho, Usuário Externo**, em 06/12/2024, às 14:36, conforme horário oficial de Brasília, com fundamento no art. 23, inciso II, da [Portaria nº 912/2017](#) da Anatel.



A autenticidade deste documento pode ser conferida em <http://www.anatel.gov.br/autenticidade>, informando o código verificador **12987578** e o código CRC **40092A8F**.

ANEXO AO TERMO DE EXECUÇÃO DESCENTRALIZADA

PLANO DE TRABALHO

DADOS CADASTRAIS DA UNIDADE DESCENTRALIZADORA

Unidade Descentralizadora e Responsável

Nome do órgão ou entidade descentralizador(a): Agência Nacional de Telecomunicações (ANATEL).

Nome das autoridades competentes:

- CARLOS MANUEL BAIGORRI - Presidente da Anatel - CPF:***.573.***-35
- ALEXANDRE REIS SIQUEIRA FREIRE- Conselheiro da Anatel - CPF:***.851.***-53

Nome da Secretaria/Departamento/Unidade Responsável pelo acompanhamento da execução do objeto do TED: Superintendência de Outorga e Recursos a Prestação

UG SIAFI

Número e Nome da Unidade Gestora - UG que descentralizará o crédito: 413001 - Anatel Sede;

Número e Nome da Secretaria/Departamento/Unidade Responsável pelo acompanhamento da execução do objeto do TED: 413066 - Superintendência de Outorga e Recursos a Prestação

DADOS CADASTRAIS DA UNIDADE DESCENTRALIZADA

Unidade Descentralizada e Responsável

Nome do órgão ou entidade descentralizada: Universidade Federal do Rio de Janeiro

Nome da autoridade competente: Roberto de Andrade Medronho

Número do CPF: ***.401.***-49

Nome da Secretaria/Departamento/Unidade Responsável pela execução do objeto do TED: 153115 - UNIVERSIDADE FEDERAL DO RIO DE JANEIRO

UG SIAFI

Número e Nome da Unidade Gestora - UG que receberá o crédito: 153115 - UNIVERSIDADE FEDERAL DO RIO DE JANEIRO

Número e Nome da Secretaria/Departamento/Unidade Responsável pela execução do objeto do TED: 15236 - UNIVERSIDADE FEDERAL DO RIO DE JANEIRO

OBJETO DO TERMO DE EXECUÇÃO DESCENTRALIZADA

Esta proposta aborda a aplicação de técnicas de Inteligência Artificial (IA) na gestão do espectro radioelétrico, com foco no planejamento e em seu uso eficiente. O espectro é um recurso escasso e valioso para sistemas de comunicação, sendo fundamental para tecnologias como 5G, 6G, e IoT. Através da adoção de métodos avançados de IA, são propostas ferramentas que permitam a previsão da demanda futura de espectro, a alocação dinâmica e adaptativa, e o monitoramento contínuo, otimizando o uso das frequências disponíveis.

As metas do projeto incluem a análise de abordagens de IA já utilizadas ou com potencial de utilização na gestão do espectro, a avaliação da utilização da IA nas tarefas do regulador e a elaboração de um plano de ação para a implantação de soluções de IA para a gestão do espectro. O projeto avalia o impacto da aplicação de IA no cenário regulatório brasileiro, propondo um roteiro de ações de curto, médio e longo prazo para que reguladores e operadoras de telecomunicações possam adotar essas soluções de forma eficaz.

A primeira meta foca o levantamento das tecnologias IA voltadas para a comunicação por rádio, especificamente nos contextos de 5G e 6G. Métodos como aprendizado de máquina supervisionado e não supervisionado, aprendizado por reforço, além de redes neurais artificiais, serão investigados para identificar sua aplicabilidade na gestão de espectro. As técnicas permitirão o desenvolvimento de sistemas inteligentes e adaptativos, capazes de gerenciar o espectro de maneira eficiente e sustentável.

A segunda meta explora o uso de IA para melhorar a previsibilidade e o controle do espectro, por meio de simulações e modelos de propagação baseados em dados. Essas simulações serão utilizadas para prever interferências, otimizar a alocação de frequências e melhorar a eficiência geral do espectro.

A terceira meta busca orientar reguladores na adoção de IA, propondo diretrizes para a implementação dessas soluções no contexto regulatório. Através do desenvolvimento de protótipos, treinamentos e workshops, o projeto visa capacitar os profissionais envolvidos, garantindo a correta implementação e operação de ferramentas de IA para a gestão de espectro.

Finalmente, o projeto oferece uma análise do impacto econômico e regulatório da adoção dessas tecnologias, estimando o retorno sobre o investimento e propondo estratégias para garantir a sustentabilidade e a conformidade com as normas vigentes.

Em resumo, este projeto tem como objetivo transformar a gestão do espectro através da IA, garantindo o uso eficiente de frequências em redes complexas e promovendo um planejamento mais dinâmico e adaptativo.

DESCRIÇÃO DAS AÇÕES E METAS A SEREM DESENVOLVIDAS NO ÂMBITO DO TED:

Este projeto será executado por sete pesquisadores e sete estudantes de graduação durante toda a vigência do projeto. Assim, todos os participantes estarão envolvidos em todas as metas. Cada um dos estudantes será orientado por um dos pesquisadores. Cada produto entregue será responsabilidade de um grupo de estudantes e pesquisadores. A entrega final de cada produto deverá ser revisada por um dos pesquisadores. O valor gasto em cada meta, mostrado no item 9, é proporcional ao número de meses empregado na meta e considerando que para cada mês do projeto são necessárias sete bolsas de estudante e sete de pesquisadores.

Os pesquisadores e pesquisadoras participantes são:

Marcello Luiz Rodrigues de Campos;
Luís Henrique Maciel Kosmowski Costa;
Miguel Elias Mitre Campista;
Rodrigo de Souza Couto;
Fernanda Duarte Vilela Reis de Oliveira;
Natanael Nunes de Moura Junior; e
Pedro Henrique Cruz Caminha.

Os sete pesquisadores são membros do Programa de Engenharia Elétrica da COPPE/UFRJ, possuindo diversas publicações nas áreas de Inteligência Artificial, Telecomunicações e áreas correlatas. Os pesquisadores estão distribuídos entre quatro laboratórios, especializados em IA, telecomunicações, processamento de sinais e todas as camadas de redes de computadores. A equipe de pesquisadores é formada por pesquisadores em diversos níveis de maturidade de pesquisa, incluindo três bolsistas PQ do CNPq e dois Jovens Cientistas do Nosso Estado (FAPERJ).

A parte da equipe composta por estudantes de graduação será indicada no início do projeto.

As diferentes metas do projeto são descritas a seguir.

Meta 1 - Técnicas e abordagens de Inteligência Artificial utilizadas ou passíveis de utilização nas radiocomunicações

A digitalização progressiva está levando a um aumento rápido no número de dispositivos conectados em rede e exige sistemas modernos de comunicação sem fio que sejam ao mesmo tempo poderosos e eficientes em termos de recursos. Métodos de inteligência artificial (IA) podem contribuir significativamente para isso e já são utilizados com sucesso nas camadas superiores dos protocolos de sistemas 4G/5G. Em contraste, bons e práticos modelos matemáticos e abstratos para a camada física (PHY) e para o acesso ao meio (MAC) foram empregados até agora sob suposições idealizadas, o que possibilitou o desenvolvimento de procedimentos e algoritmos eficientes. No entanto, a crescente complexidade dos sistemas, com um número cada vez maior de dispositivos, as crescentes demandas por taxas de dados e baixa latência, bem como a diversidade de serviços a serem fornecidos (banda larga, comunicação esporádica e/ou muito confiável entre máquinas, chamadas de emergência, telemedicina, IoT, etc.), estão levando as abordagens anteriores baseadas em modelos ao seu limite. Assim, parece inevitável que novos conceitos sejam necessários.

Outro ponto de destaque é a importância de utilizar informações de contexto para melhorar a eficiência de redes de comunicação sem fio, adaptando-as às condições ambientais e às necessidades dos usuários. A meta 1 também deve avaliar como métodos de aprendizado de máquina (ML) podem ser usados para enriquecer essas informações e otimizar a gestão de redes. O contexto operacional, nesse caso, envolve informações sobre ambiente, dispositivos, links de comunicação e aplicações. A percepção de contexto permite que as redes adaptem parâmetros de transmissão e realizem ajustes dinâmicos para melhorar a qualidade do serviço (QoS) e a experiência do usuário (QoE). O enriquecimento de contextos como localização geográfica, qualidade de sinal, padrões de tráfego, características de interferência e desempenho dos canais pode trazer toda uma gama de novas informações para a tomada de decisão na operação da rede. Exemplos de aplicação desta abordagem incluem técnicas de detecção e predição de ocupação de espectro em redes cognitivas, utilizando aprendizado supervisionado e não supervisionado, e métodos de aprendizado por reforço para configuração autônoma de sistemas de comunicação.

Os requisitos muitas vezes conflitantes em termos de confiabilidade, taxa de transmissão, número de terminais por área, latência, recursos de rádio disponíveis, eficiência energética, complexidade e custos de hardware estão tornando a implementação com métodos tradicionais cada vez mais difícil. Se, por exemplo, a modelagem matemática do problema não for mais possível (déficit de modelo) ou levar a modelos muito complexos (déficit de algoritmo), métodos de ML baseados em dados representam uma abordagem promissora para compreender o modelo ou para o desenvolvimento de sistemas e tecnologias.

No âmbito da meta 1, a proposta é a realização de uma pesquisa fundamental das tecnologias orientadas por IA para comunicação por rádio, com foco na quinta geração de rádio móvel (5G), na sexta geração (6G) e em seu desenvolvimento futuro. Em particular, serão pesquisados conceitos para um melhor entendimento do modelo com base em campanhas de medição, métodos baseados em IA para estimativa de parâmetros, otimização orientada por dados dos procedimentos de transmissão e recepção, além de treinamento baseado em IA para implementações de hardware.

O objetivo geral da meta 1 é a pesquisa e documentação de aplicação de sistemas de comunicação inteligentes (baseados em modelos de inteligência artificial) e adaptativos que utilizem os recursos existentes de forma eficiente e sustentável, e que sejam baseados nas especificações do sistema 5G/6G, em aplicações 5G/6G e perspectivas futuras. Desde a camada PHY e MAC até a implementação de hardware em FPGA e o design de ASIC, os componentes

essenciais de comunicação são analisados e otimizados com diferentes métodos de IA. As propriedades dos métodos de IA conhecidos são identificadas de acordo com cada problema e possíveis limitações em sua aplicabilidade são analisadas.

A partir do desenvolvimento do conceito teórico, os procedimentos operativos poderão ser pesquisados e demonstrados por meio de implementação prototípica, levando em consideração questões de implementação e parâmetros e cenários específicos do sistema 5G (possivelmente 6G). Duas abordagens diferentes poderão ser seguidas.

O Método do Gargalo de Informação (IBM) é uma abordagem geral motivada pela teoria da informação para aprender métodos de processamento de informações. Esse método já foi utilizado com sucesso para a otimização de quantizadores e para o design de decodificadores discretos, onde a decodificação iterativa é implementada de maneira muito eficiente com a ajuda de tabelas de consulta aprendidas (LUTs). O objetivo é estender essa abordagem para estruturas de códigos mais gerais e implementar a realização de hardware em conjunto com os parceiros do projeto. Isso permitirá a análise da eficiência de implementação e das métricas de mensagens correspondentes sob condições de implementações de hardware realistas.

Em uma próxima fase do projeto, conceitos para equalização MIMO e decodificação de canal poderão ser explorados usando técnicas de aprendizado de máquina. Em particular, a decodificação eficiente de códigos de canal curtos com alta confiabilidade é um desafio e será abordado tanto com redes neurais aprendidas quanto por adaptação baseada em ML de métodos de decodificação convencionais. Em princípio, a equalização MIMO comum e a decodificação de canal permitem uma redução de latência, ao contrário do processamento sequencial ou iterativo, que é comumente adotado. A partir de abordagens híbridas que combinam componentes baseados em redes neurais com algoritmos clássicos, uma estrutura comum de receptor baseada em redes neurais será desenvolvida, aprendida e analisada passo a passo em relação ao equilíbrio entre desempenho e complexidade.

Com base nos casos de uso 5G identificados, poderá ser estabelecido um link de transmissão 5G baseado em SDR e os procedimentos de recepção baseados em IA serão implementados. Dessa forma, a adaptação dos procedimentos a sistemas e cenários de transmissão reais é viabilizada e a adequação prática dos sistemas de transmissão baseados em IA é comprovada.

Outro ponto de interesse da meta 1 é a avaliação do uso de métodos de IA para aumentar a percepção de contexto em sistemas de comunicação por rádio. A importância de utilizar informações de contexto para melhorar a eficiência de redes de comunicação sem fio, adaptando-as às condições ambientais e às necessidades dos usuários. Cabe destacar como métodos de aprendizado de máquina (ML) podem ser usados para enriquecer essas informações e otimizar a gestão de redes.

Nesta etapa, também deverão ser abordadas técnicas de Previsão de Espectro (Spectrum Forecasting) e em Modelos de Consumo de Espectro (Spectrum Consumption Models – SCM), com diferentes cenários de aplicação para uso dinâmico, compartilhado e eficiente deste recurso escasso (ex: IEEE 1900.5.2 standard).

DETALHAMENTO

Os métodos de aprendizado de máquina podem ser amplamente organizados em três grupos: aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço.

No aprendizado supervisionado, um modelo preditivo é construído usando dados de treinamento que consistem em entradas junto com os valores de saída correspondentes. O objetivo do modelo é minimizar a diferença entre a saída do modelo e os valores reais. Existem muitos métodos de aprendizado supervisionado, que serão brevemente descritos a seguir.

k-nearest neighbors (kNN) é um método não linear em que a saída prevista é a média dos valores dos k vizinhos mais próximos da entrada. A métrica de distância mais comum no espaço de entrada é a distância Euclidiana. Os modelos kNN são fáceis de interpretar, rápidos para treinar e possuem poucos parâmetros para ajustar. No entanto, a precisão das previsões é geralmente limitada. No contexto da percepção de rádio, o método kNN tem sido utilizado, entre outras aplicações, para sensoriamento de espectro e reconhecimento de modulação. Porém, sua precisão limitada o torna mais adequado para ambientes com restrição de recursos.

O método **Naive Bayes (NB)** é baseado no teorema de Bayes para calcular probabilidades usando probabilidades anteriores. Um classificador Naive Bayes assume que todas as características são condicionalmente independentes. Ele requer uma pequena quantidade de dados de treinamento e é recomendado quando a dimensionalidade das entradas é alta.

As **árvores de decisão (DTs)** são um modelo em forma de fluxograma no qual cada nó interno representa um teste em um atributo. Cada nó folha representa uma resposta, e um ramo representa o resultado do teste. As DTs possuem parâmetros como profundidade desejada e o número de folhas na árvore. Elas não exigem nenhum conhecimento prévio sobre os dados e são robustas contra outliers ou ruídos nas etiquetas dos dados. O custo de complexidade ao usar uma árvore é logarítmico no número de pontos de dados fornecidos para o treinamento. Árvores de decisão podem ser tendenciosas se algumas classes dominarem o conjunto de treinamento, por isso é necessário um conjunto de dados equilibrado antes do ajuste. Ao contrário de outros métodos, as árvores de decisão podem processar dados categóricos e numéricos sem normalização prévia. Árvores de decisão foram aplicadas para sensoriamento de espectro e reconhecimento de modulação.

Máquinas de vetores de suporte (SVMs) utilizam dados de treinamento para encontrar um hiperplano que separa as classes com a maior margem possível. Os pontos amostrais que formam a margem são chamados de vetores de suporte e estabelecem o modelo final. Quando um bom separador linear não pode ser encontrado, técnicas de kernel são usadas para projetar os pontos de dados em um espaço de maior dimensão, onde se tornam linearmente separáveis. Portanto, a escolha correta dos parâmetros do kernel é crucial para obter bons resultados. Em geral, este método apresenta alta precisão em previsões e pode lidar bem com problemas não lineares ao usar métodos de kernel apropriados. No entanto, a busca exaustiva no espaço de parâmetros torna a tarefa complexa. A solução ótima encontrada pelas SVMs é convexa, o que garante uma solução única, diferentemente das redes neurais, que fornecem múltiplas soluções associadas a mínimos locais. SVMs podem ter alto desempenho para problemas pequenos, mas seus requisitos de computação e armazenamento aumentam rapidamente com o número de vetores de treinamento. SVMs não são invariantes a escala, portanto os dados precisam ser redimensionados antes de serem fornecidos como entrada. Um classificador SVM pode ser usado para sensoriamento de espectro e tomada de decisão.

Uma **rede neural artificial (RNA)** é um modelo de aprendizado estatístico que consiste em nós interconectados, chamados neurônios. Um neurônio recebe informações de neurônios vizinhos e gera uma saída dependendo de suas funções de ativação. As forças de conexão entre os neurônios são representadas por pesos adaptativos. Durante o processo de aprendizado, os pesos são ajustados até que a saída da rede seja aproximadamente igual à saída desejada. Como um tipo especial de rede neural, as redes neurais convolucionais (CNNs) usam operações de convolução com um conjunto de kernels (filtros) em vez de utilizar conexões completas entre as camadas de neurônios. Como as operações de convolução são invariantes em termos de translação, as CNNs são úteis para analisar dados espaciais. Outro tipo de rede neural, as redes neurais recorrentes (RNNs), são projetadas para modelar dados sequenciais, onde existem correlações sequenciais entre as amostras. RNNs usam conexões recorrentes de um neurônio em uma camada para neurônios em camadas anteriores. No treinamento das RNNs tradicionais, ocorrem frequentemente problemas de gradiente que desaparece ou explode, tornando-as difíceis de treinar. A long short-term memory (LSTM) é um tipo especial de RNN que mitiga esses problemas introduzindo um conjunto de portas. A estrutura de conexão entre as camadas de neurônios, o processo de aprendizado para atualizar os pesos das interconexões e a função de ativação que converte a entrada ponderada de um neurônio em sua ativação de saída são os parâmetros mais importantes a serem ajustados. RNAs podem enfrentar um treinamento lento dependendo do tamanho da rede. Elas fornecem múltiplas soluções associadas a mínimos locais, e, por essa razão, podem não ser robustas a diferentes amostras.

No **aprendizado não supervisionado**, são fornecidos apenas dados não rotulados, e o objetivo de um modelo é encontrar um padrão nos dados. As aplicações mais comuns de métodos de aprendizado não supervisionado são agrupamento, redução de dimensionalidade e detecção de anomalias.

O objetivo do **agrupamento** é identificar grupos de dados e construir uma representação das entradas. Métodos de agrupamento podem ser classificados como não sobrepostos, hierárquicos e sobrepostos. Entre os métodos não sobrepostos, o agrupamento K-means e os mapas auto-organizáveis (SOMs) são os mais populares. O agrupamento K-means visa particionar observações em clusters, de modo que cada observação pertença a um cluster com a média mais próxima e a variância intra-cluster seja minimizada. O K-means é comumente aplicado para melhoria de percepção de contexto, principalmente no

sensoriamento. Em mapas auto-organizáveis (SOM), dados não rotulados são alimentados em uma rede neural para produzir uma representação discretizada de baixa dimensão do espaço de entrada das amostras de treinamento, chamada de mapa. No agrupamento sobreposto, uma observação pode pertencer a mais de um cluster simultaneamente. Os modelos de mistura Gaussiana pertencem a essa classe de métodos.

Os métodos de **redução de dimensionalidade** produzem modelos de baixa dimensão a partir de conjuntos de dados de alta dimensão. A análise de componentes principais (PCA) faz isso criando novas combinações de características, que projetam os dados em um subespaço de menor dimensão identificando características correlacionadas na distribuição dos dados. PCA pode ser útil no reconhecimento de modulação.

O objetivo do **aprendizado por reforço (RL)** é aprender, por meio de um agente dedicado, uma política ótima (ou subótima) que maximize a chamada função de recompensa, baseada nas recompensas imediatas observadas. O RL pode ser baseado em modelos (onde um modelo dedicado é gerado) ou livre de modelos. Um modelo básico de aprendizado por reforço consiste em estados do ambiente, ações possíveis, regras para transição entre estados, recompensas das transições e regras de observação. O aprendiz, chamado de agente, interage continuamente com o ambiente selecionando ações. O ambiente muda respondendo a essas ações e o agente recebe recompensas numéricas como resposta. No aprendizado por reforço, o agente tenta maximizar as recompensas ao longo do tempo. O aprendizado pode ser centralizado em um único agente ou distribuído entre vários agentes.

Os entregáveis da Meta 1 serão apresentados por meio de uma série de relatórios técnicos e atividades práticas, organizados para cobrir aspectos cruciais da aplicação de inteligência artificial (IA) na gestão eficiente do espectro de rádio, descritos a seguir. Note que ao lado de cada relatório há o número de estudantes e pesquisadores envolvidos na sua concepção. Na tarefa de workshop toda a equipe estará envolvida.

(1) Relatório Técnico sobre Técnicas e Abordagens de IA Utilizadas ou Passíveis de Utilização (2 estudantes e 2 pesquisadores). Este relatório oferecerá uma análise detalhada sobre as técnicas de IA aplicáveis à gestão de espectro, como aprendizado de máquina, aprendizado profundo e redes neurais. Incluindo estudos de caso e comparações entre diferentes técnicas, o documento fornecerá uma base sólida para entender quais métodos são mais eficazes e como podem ser adaptados ao contexto específico de comunicação sem fio.

(2) Relatório com Detalhamento das Diferentes Formas de Avaliação do Uso Eficiente do Espectro e Como a IA Pode Atuar Neste Processo (2 estudantes e 2 pesquisadores). Este relatório abordará os métodos tradicionais de avaliação do uso do espectro e analisará como a IA pode ser integrada a esses processos para melhorar a eficiência, oferecendo insights sobre ferramentas e modelos de IA que podem ser implementados para essa finalidade.

(3) Workshop Meta 1 (7 estudantes e 7 pesquisadores), que será uma oportunidade prática para capacitar os participantes no uso de ferramentas de IA aplicadas à previsão e gestão de espectro. Durante o workshop, especialistas da indústria, academia e órgãos reguladores compartilharão suas perspectivas sobre as melhores práticas e inovações na área, e os participantes terão acesso a materiais didáticos desenvolvidos para garantir um aprendizado contínuo.

(4) Relatório com Projeções Futuras e Cenários de Uso (1 estudante e 1 pesquisador), que explorará as tendências e previsões a longo prazo para o uso do espectro. Com base na evolução tecnológica e crescimento da demanda, o relatório avaliará diferentes cenários de utilização e abordará estratégias de IA que poderiam otimizar o espectro em cada caso, além de avaliar o impacto econômico dessas estratégias.

(5) Relatório de Análise de Risco e Mitigação (2 estudantes e 2 pesquisadores), que identificará os riscos relacionados à implementação de soluções de IA na gestão do espectro e desenvolverá estratégias de mitigação. O relatório também cobrirá aspectos de regulamentação e conformidade, assegurando que as soluções propostas estejam alinhadas com as normas vigentes.

Esses produtos e relatórios, elaborados de forma integrada, proporcionarão uma visão abrangente da aplicação de IA na gestão do espectro, cobrindo desde a análise técnica das técnicas disponíveis até a capacitação prática e a avaliação de riscos e tendências futuras.

Meta 2: Uso de IA na Gestão do Espectro

A Inteligência Artificial (IA) é uma ferramenta poderosa no planejamento do espectro, oferecendo meios para otimizar o uso de frequências de rádio. O planejamento do espectro pode usar técnicas de IA para distribuir e destinar frequências de forma eficiente, bem como identificar faixas de espectro subutilizadas. Métodos de aprendizado de máquina e aprendizado profundo têm sido usados para criar modelos que possam automaticamente analisar padrões de uso e identificar oportunidades de alocação eficiente. [Camelo et al. 2020] propõem uma abordagem baseada em aprendizado profundo para identificar padrões de tráfego diretamente a partir de dados do espectro, sem depender da análise intrusiva de pacotes de dados. O trabalho utiliza redes neurais convolucionais (CNNs) para diferenciar tipos de tráfego (como TCP e UDP) e padrões de tráfego com diferentes ciclos e taxas de transmissão, analisando imagens que representam o espectro no tempo e tempo-frequência. Essa abordagem permite detectar padrões diretamente dos dados espectrais. Além disso, o trabalho cria grandes conjuntos de dados sintéticos, gerados por simuladores de rede, para treino do modelo.

A análise de padrões de uso do espectro é útil porque permite identificar não apenas a ocupação dos canais, mas também o tipo de tráfego e sua intensidade. Isso possibilita a alocação dinâmica e eficiente de frequências, ajustando-se a diferentes padrões de uso, como momentos de alta ou baixa atividade e diferentes tipos de tráfego (por exemplo, TCP vs. UDP do trabalho de Camelo et al.). Assim, operadores podem tomar decisões mais informadas sobre o uso do espectro, otimizando o desempenho da rede e melhorando a eficiência geral de alocação. Essa análise pode ser de camadas superiores, como em [Camelo et al. 2020], ou de aspectos até a camada física. [Kulin et al. 2018], por exemplo, usam redes neurais profundas para identificar padrões de modulação e interferência no espectro. A abordagem aplica redes neurais convolucionais (CNNs) em representações temporais e de frequência dos sinais sem fio, mostrando que diferentes representações dos sinais (como amplitude/fase, domínio do tempo e domínio da frequência) afetam a precisão das tarefas de identificação do padrão de uso do espectro.

Outro uso de IA no planejamento do espectro é a criação de modelos de propagação que podem prever o desempenho de diferentes tecnologias e aplicação em uma faixa do espectro. Diferenças nas características de propagação de ondas, como atenuação e bloqueio, são críticas para a precisão no planejamento do espectro [Sun et al. 2018]. O trabalho de [Seretis et al. 2021] aborda como técnicas de aprendizado de máquina são usadas para aprimorar a precisão de modelos de propagação de ondas de rádio, superando as limitações de modelos tradicionais. Os modelos empíricos tradicionais, como Okumura-Hata ou Walfish-Bertoni, são baseados em medições e oferecem eficiência computacional. Porém, esses modelos têm precisão limitada em cenários complexos, devido à falta de detalhamento sobre efeitos de propagação, como difração e multipercurso. Por outro lado, modelos determinísticos, como ray-tracing ou métodos baseados em equações diferenciais, fornecem previsões mais precisas, mas são altamente específicos ao ambiente e computacionalmente intensivos. Os modelos baseados em IA, como redes neurais profundas, balanceiam essa dicotomia ao serem treinados com dados de medições ou simulações para capturar efeitos complexos de propagação de ondas de rádio, mantendo uma eficiência computacional significativa. Isso permite que esses modelos sejam flexíveis para prever a perda de caminho, difração, e efeitos de espalhamento em uma ampla variedade de ambientes, desde urbanos até ambientes fechados como túneis, melhorando o planejamento do espectro ao fornecer previsões mais precisas para diferentes cenários e frequências. Essas técnicas são úteis para o planejamento do espectro ao prever a interferência e o desempenho em diferentes ambientes e frequências, levando em conta características topográficas e fatores de propagação de sinais, como perda por difração e condições de visada (LoS e NLoS) [Seretis et al. 2021].

Outro tipo de ferramenta importante são simulações e modelos preditivos para testar e validar a eficácia dos algoritmos de IA no Planejamento do Espectro. Esses modelos auxiliam na previsão de demandas futuras de frequências, permitindo ajustar a alocação para acomodar novos usuários ou serviços. [Kliks et al. 2020] expandem o papel das simulações e modelos preditivos ao introduzir a ideia de "Radio Service Maps" (RSMs), que são mapas detalhados contendo informações como padrões de tráfego, mobilidade e qualidade do sinal. Essas RSMs permitem que algoritmos de IA façam ajustes dinâmicos e eficientes no planejamento do espectro, baseando-se em dados contextuais como distribuição de tráfego e trajetórias dos usuários. O artigo demonstra que, para redes 6G, esses modelos contextuais são fundamentais para o gerenciamento dinâmico do espectro (DSM), proporcionando ajustes em tempo real e maior eficiência no uso das frequências, além de permitir o planejamento preditivo para acomodar novos usuários ou mudanças na demanda. Essas RSMs integram dados heterogêneos, como padrões de uso de frequência e mobilidade dos usuários, ajudando a otimizar recursos e minimizar interferências. Com a aplicação de IA para processar grandes volumes de dados, é possível criar modelos de alocação de espectro que respondem rapidamente a alterações na rede, melhorando a eficiência e o desempenho geral.

O conhecimento obtido nesta meta será complementado com estudos de caso sobre o uso de IA no planejamento do espectro por agências reguladoras, como as iniciativas da Federal Communications Commission (FCC) nos Estados Unidos. Em 2023, a FCC lançou uma "Notice of Inquiry" (NOI) para explorar como a IA e o aprendizado de máquina podem melhorar a compreensão e gerenciamento do uso do espectro por agências reguladoras, incluindo mecanismos de compartilhamento e identificação de subutilização do espectro. A FCC tem como objetivo entender a ocupação do espectro em termos de geografia, frequência e tempo, para otimizar políticas de espectro e permitir dispositivos mais inteligentes que utilizam IA para evitar interferências e se adaptar dinamicamente às condições do espectro [Venable LLP 2023]. Além disso, a FCC, juntamente com a National Science Foundation (NSF), organizou workshops para explorar como a IA pode transformar a gestão de espectro e aumentar a resiliência de redes de comunicação. Essas discussões cobrem como a IA pode ajudar na otimização do tráfego de rede, melhorar a política de espectro, facilitar o compartilhamento de frequências e ajudar na gestão de redes resilientes e autorreparáveis [FCC 2023].

O uso de inteligência artificial (IA), e principalmente aprendizado de máquina, tem sido destacado como uma abordagem para lidar com os desafios de acesso dinâmico e compartilhamento de espectro (Spectrum Sharing - SS) em redes 5G e B5G. Em cenários de espectro dinâmico, nos quais múltiplos dispositivos e aplicações competem por recursos limitados de frequência, essas técnicas podem aprimorar a alocação de espectro, permitindo identificar espaços não utilizados e ajustar dinamicamente a alocação conforme a demanda.

O SS envolve estratégias e regras para otimizar a utilização de frequências disponíveis, especialmente em redes nas quais há múltiplos usuários e grande demanda por recursos espectrais. Assim, é necessário destinar de forma eficiente porções de espectro para usuários secundários, garantindo que esses usuários usem essas faixas de forma oportunista e sem interferir nos usuários primários, que possuem direitos de operação prioritários. Para o funcionamento correto do compartilhamento é necessário um controle adaptativo às condições do espectro, coordenando vários usuários secundários para garantir que todos possam acessar o espectro sem entrar em conflito com os usuários primários. Outro elemento importante é o sensoriamento de espectro por meio de ferramentas de monitoramento, que envolve a detecção ativa da presença de usuários primários para determinar a disponibilidade do espectro para outros usuários. Essas ferramentas permitem o handoff do espectro, que é a realocação ou troca de faixas quando um usuário secundário causar interferência a um usuário primário ou quando mudanças geográficas ou de requisitos de serviço exigem que o usuário secundário migre para uma faixa de espectro mais adequada [Patil et al. 2024].

O conjunto de soluções de controle adaptativo e compartilhamento de espectro, além das ferramentas de monitoramento, compõem sistemas de Dynamic Spectrum Access (DSA). Sistemas com DSA permitem o uso flexível e eficiente do espectro, na qual usuários secundários podem acessar as faixas de frequência de forma oportunista, desde que não causem interferência nos usuários primários, que possuem direitos prioritários. Um exemplo de abordagem para gerenciar o espectro nesse contexto é apresentado por [Song et al. 2021], que utilizam uma DQN (Deep Q-network), uma forma de aprendizado por reforço. Nesse trabalho, os usuários de DSA ajustam de forma autônoma a alocação de espectro sem depender de um controle centralizado ou informações precisas do canal. O estado da DQN é definido como um vetor de potência de transmissão nos canais disponíveis, representando o uso atual do espectro. As ações possíveis incluem ajustar a potência de transmissão em cada canal (aumentar, diminuir ou manter). A DQN calcula as recompensas com base na eficiência espectral e na interferência gerada aos usuários primários, permitindo que a rede neural aprenda a otimizar as ações para melhor utilizar o espectro sem causar interferência excessiva aos usuários prioritários.

Apesar de o DSA melhorar a eficiência do espectro em cenários de compartilhamento, seu uso possui diversos desafios, principalmente relacionados à coordenação eficiente e à redução de interferência. Em ambientes com alta densidade de tráfego e frequências como ondas milimétricas (mmWave) e Tera-Hertz (THz), a variabilidade do canal e a interferência se tornam problemas significativos. Adicionalmente, o uso de IA para melhorar a eficiência espectral e energética requer algoritmos que sejam eficientes para redes de baixa latência e cobertura limitada.

O uso de IA no gerenciamento de DSA não apenas aborda a eficiência espectral, mas também enfrenta desafios de segurança e privacidade, que são críticos em redes 5G e B5G [Wang et al. 2022]. Técnicas de aprendizado de máquina podem ser usadas para identificar e mitigar ataques como o "Primary User Emulation" (PUE), nos quais invasores simulam o comportamento de usuários primários para monopolizar o espectro, ou "Spectrum Sensing Data Falsification" (SSDF), que manipula dados de sensoriamento para enganar a rede sobre o estado real do espectro. Frameworks de segurança baseados em aprendizado de máquina devem considerar aspectos como a confidencialidade dos usuários, integridade dos dados, disponibilidade do espectro e autenticação robusta. Ferramentas como aprendizado por reforço profundo podem ajudar a detectar padrões de tráfego suspeitos e tomar decisões proativas para mitigar riscos, enquanto redes neurais convolucionais (CNNs) podem ser utilizadas para identificar anomalias no uso do espectro. Além disso, o uso de técnicas como aprendizado federado possibilita que o aprendizado seja descentralizado, preservando a privacidade dos dados locais dos usuários e tornando os sistemas de gerenciamento de espectro mais resilientes a ataques centralizados.

A partir do estudo das diversas formas de usar IA na gestão do espectro, serão produzidos os seguintes relatórios, descritos a seguir. Note que ao lado de cada relatório há o número de estudantes e pesquisadores envolvidos na sua concepção. Na tarefa de workshop toda a equipe estará envolvida.

(1) Relatório sobre Formas de Uso de IA no Planejamento de Espectro (2 estudante e 2 pesquisador): A Inteligência Artificial (IA) proporciona uma abordagem inovadora para o planejamento do espectro, permitindo a distribuição e destinação de frequências de maneira mais eficiente. Algoritmos de aprendizado de máquina e redes neurais convolucionais (CNNs) podem analisar padrões de uso em diferentes momentos e locais, ajustando a alocação de frequências com base nas variações de tráfego. Esses métodos possibilitam a identificação de faixas subutilizadas e o ajuste dinâmico da alocação, melhorando o desempenho da rede. Além disso, a capacidade de analisar representações temporais e de frequência dos sinais permite maior precisão na identificação e separação de diferentes tipos de tráfego, contribuindo para uma alocação mais eficiente e dinâmica das frequências. Por fim, serão apresentadas simulações e modelos preditivos para validar a eficácia desses algoritmos e estudos de caso destacando implementações bem-sucedidas ao redor do mundo.

(2) Relatório sobre Formas de Uso de IA na Consignação de Frequências e no Licenciamento de Estações (1 estudante e 1 pesquisador): O processo de consignação de frequências e licenciamento de estações pode ser significativamente aprimorado com o uso de IA. Ferramentas inteligentes, baseadas em técnicas de aprendizado profundo, podem automatizar a consignação de frequências, respondendo em tempo real às demandas e mudanças de interferência. Isso inclui o ajuste dinâmico das alocações, minimizando os tempos de espera e aumentando a eficiência do uso do espectro. O licenciamento de estações também pode ser acelerado por algoritmos de IA que identificam oportunidades de otimização e verificam automaticamente a compatibilidade dos dispositivos, aprimorando a precisão e rapidez da aprovação de licenças. Plataformas integradas que empregam IA podem acelerar o processo de aprovação e melhorar a precisão das avaliações, reduzindo burocracias e aumentando a qualidade do serviço oferecido.

(3) Relatório sobre Formas de Uso de IA no Acesso Dinâmico e/ou Compartilhado de Espectro (1 estudante e 1 pesquisador): Em cenários de espectro dinâmico, nos quais múltiplos dispositivos competem por frequências limitadas, a IA desempenha um papel crucial na alocação eficiente e compartilhamento de espectro. Técnicas de IA, como redes neurais profundas, podem identificar padrões de tráfego em tempo real e ajustar a alocação conforme a demanda. O uso de IA para Dynamic Spectrum Access (DSA) facilita o controle adaptativo do acesso ao espectro, possibilitando que usuários secundários acessem faixas de frequência de maneira oportunista sem interferir nos usuários primários. Um dos exemplos é o uso de aprendizado por reforço para ajustar autonomamente a alocação de espectro, otimizando o uso sem depender de controle centralizado.

(4) Relatório sobre Formas de Uso de IA na Radiomonitoragem (1 estudante e 1 pesquisador): A radiomonitoragem é essencial para detectar interferências e identificar padrões de uso do espectro. Com IA, é possível analisar sinais em tempo real para detectar interferências, modulações e padrões anômalos. A análise automática de sinais por redes neurais profundas permite identificar tipos de tráfego, interferências e até mesmo o nível de ocupação dos canais, aprimorando a eficiência e a precisão das atividades de radiomonitoragem. Além disso, o uso de ferramentas de IA para a geração de relatórios automatizados simplifica o processo de tomada de decisão para reguladores, fornecendo informações valiosas sobre o uso do espectro.

(5) Relatório sobre Formas de Uso de IA Aplicada em Sistemas de Gestão de Espectro (1 estudante e 1 pesquisador): Sistemas de gestão de espectro integrados com IA podem oferecer uma visão global e coordenada de todas as atividades relacionadas à alocação, monitoração e planejamento do espectro. Tais sistemas utilizam métodos de aprendizado de máquina para prever cenários futuros de uso e avaliar a convivência entre diferentes serviços. Por exemplo, é possível incorporar dados contextuais de tráfego e mobilidade para facilitar o ajuste dinâmico do espectro, permitindo a

predição e avaliação de diferentes cenários de convivência e coordenação entre serviços. Propostas de interfaces amigáveis e intuitivas podem garantir que reguladores e operadores usem as ferramentas de IA de forma eficaz, melhorando a experiência do usuário.

(6) Workshop Meta 2 (7 estudantes e 7 pesquisadores): O workshop prático será uma oportunidade para capacitar os profissionais na aplicação de IA para gestão de espectro, abordando desde conceitos teóricos até demonstrações práticas. Ferramentas como redes neurais convolucionais e métodos de aprendizado profundo serão discutidas, junto com exemplos reais e simulações. Especialistas da academia e da indústria participarão para compartilhar melhores práticas e inovações na área, enquanto materiais didáticos detalhados fornecerão suporte contínuo aos participantes, promovendo uma compreensão aprofundada do uso de IA no contexto de gestão de espectro.

(7) Relatório de Análise de Impacto Regulatório e Econômico (1 estudante e 1 pesquisador): A implementação de IA na gestão do espectro traz implicações regulatórias e econômicas que devem ser analisadas de maneira abrangente. Este relatório abordará como a IA pode aprimorar a eficiência da alocação de frequências e o impacto econômico positivo de uma melhor gestão espectral, com análise detalhada dos custos de implementação e benefícios a longo prazo. O uso de IA, como proposto pela Federal Communications Commission (FCC) e iniciativas da National Science Foundation (NSF), destaca o potencial dessas tecnologias para melhorar a resiliência das redes e promover políticas de espectro mais inteligentes, resultando em uma economia mais eficiente e uma alocação espectral otimizada.

Meta 3 - Ações para adoção de soluções de IA pelo regulador

A Meta 3 prevê a elaboração de produtos capazes de guiar o regulador na adoção de soluções de IA para suas atividades regulatórias. A adoção de soluções de IA é parte de um campo de estudo denominado MLOps [Mäkinen et al. 2021]. Esse campo de estudo propõe uma arquitetura para o desenvolvimento e adoção de soluções em IA [Kreuzberger et al. 2023]. A Meta 3 deve orientar o regulador a estabelecer um fluxo capaz de implantar uma solução inicial de IA para regulação do espectro e, ao mesmo tempo, um fluxo de desenvolvimento incremental da solução, de forma que alterações nas características da regulação de espectro possam ser rapidamente incorporadas à solução. Assim, as ações da Meta 3 devem auxiliar o regulador a alcançar os seguintes objetivos:

- O domínio de um **algoritmo** eficiente;
- A posse de **dados** adequados;
- O acesso à **infraestrutura computacional** suficiente;
- A participação de **peçoal** capacitado; e
- A adequação às **leis e normas** vigentes.

Cada um desses aspectos é detalhado a seguir.

O domínio de um determinado **algoritmo** de IA é relacionado à escolha e à implementação do algoritmo mais adequado para a tarefa em questão. Devem ser levados em consideração características como desempenho, eficiência de recursos e robustez a falhas. Existem bibliotecas bem estabelecidas para a implementação de algoritmos de IA. A Meta 3 deve ser capaz de orientar o regulador na escolha da biblioteca e em possíveis ajustes para a adequação da biblioteca às necessidades do regulador.

Os **dados** devem estar devidamente formatados e filtrados para o bom funcionamento do algoritmo. Essa preocupação deve se dar tanto na fase de treinamento quanto na fase de produção. Os procedimentos de coleta, transformação e armazenamento de dados devem seguir as regulamentações vigentes e as boas práticas relativas à segurança de dados e privacidade de usuários. Os artefatos e produtos da Meta 3 devem auxiliar o regulador a estabelecer um procedimento de coleta de dados, transformação de dados e filtragem de dados que possa alimentar sua IA.

A execução de modelos de IA juntamente com a coleta, transformação e armazenamento de dados podem ser intensivos no uso de **infraestrutura computacional**. Assim, é essencial que entidades que utilizem a IA tenham infraestrutura adequada à sua disposição. O dimensionamento da infraestrutura computacional está diretamente relacionada aos modelos executados e à maneira de utilização. Adicionalmente, alguns tipos específicos de hardware podem se fazer desejáveis ou até necessários, como GPUs, por exemplo. A infraestrutura computacional pode ser de propriedade do regulador ou ser fornecida por um serviço de computação em nuvem ou borda. É necessário estimar as necessidades do operador de acordo com a utilização de recursos e com os custos de cada uma das opções. A Meta 3 deve guiar o operador na escolha da melhor opção de infraestrutura dadas as suas necessidades de operação da IA.

A implantação de um serviço de IA e a atuação com o auxílio dessa IA requer a participação de **peçoal capacitado**. Mesmo com a automação da coleta, transformação e filtragem de dados, é importante a inspeção frequente dos procedimentos. Adicionalmente, o pessoal responsável pela implantação e manutenção deve ser capaz de identificar falhas e inconsistências rapidamente. Por último, o pessoal responsável pela operação da IA deve conhecer o potencial e as limitações da ferramenta, a fim de obter resultados confiáveis. A Meta 3 deve criar condições de treinamento e capacitação do pessoal de manutenção e de operação das soluções de IA para gestão do espectro.

A coleta e manipulação de dados está submetida a determinadas **leis e regulamentações**, sendo a mais importante a Lei Geral de Proteção de Dados (LGPD) [Capanema. 2020]. Os procedimentos relativos à utilização de uma solução de IA incluem a coleta e manipulação de dados. Assim sendo, é crucial a compreensão das limitações jurídicas da operação da IA. A Meta 3 deve mapear os dados utilizados e orientar o operador com relação às obrigações legais com relação aos dados e aos algoritmos executados sobre esses dados. A Meta 3 também prevê o estudo de determinados aspectos de segurança, uma vez que é obrigatório oferecer determinadas garantias a respeito da privacidade dos dados.

Apresentam-se a seguir as atividades e produtos previstos para a meta 3. Note que ao lado de cada relatório há o número de estudantes e pesquisadores envolvidos na sua concepção. Na tarefa de treinamento e na de workshop toda a equipe estará envolvida.

(1) Relatório de ações para adoção de soluções de IA pelo regulador (2 estudantes e 2 pesquisadores).

Principal documento da Meta 3. Deve orientar o regulador na adoção de soluções de IA para a gestão do espectro. Seus principais componentes são:

Plano de implementação: descreve as fases de implementação de soluções de IA para a gestão do espectro, estabelecendo um cronograma e métricas que permitam a avaliação do percurso.

Análise de capacitação: aponta a formação e o treinamento desejado para os profissionais relacionados à implantação e operação de soluções de IA para gestão do espectro.

Diretivas de coleta, armazenamento e distribuição de dados: estabelece procedimentos para a coleta, armazenamento e distribuição de dados para as soluções de IA. Deve levar em consideração as necessidades técnicas e as limitações legais da coleta, armazenamento e distribuição de dados.

Identificação de partes interessadas: identificação de atores importantes e seus papéis para a adoção de soluções de IA para a gestão do espectro, incluindo agentes governamentais, outras autoridades reguladoras, usuários, operadoras e sociedade.

(2) Relatório de avaliações técnicas e regulatórias (1 estudante e 1 pesquisador):

Estudo de viabilidade técnica: descrição das necessidades de infraestrutura e pessoal para a operação das soluções apresentadas.

Análise de impacto regulatório: apresenta a legislação e regulação relacionada ao uso de IA para gestão do espectro e elenca as ações necessárias para a adequação.

- Análise de riscos: avalia o impacto de alterações no cenário e aponta caminhos para a construção de contra-medidas.
- (3) Treinamento e provas de conceito (PoC) (7 estudante e 7 pesquisadores):
- Treinamento: planejamento de programa de treinamento de capacitação de profissionais do regulador para a utilização das ferramentas de IA.
 - Provas de conceito: realização de PoCs em cenários reais, incluindo a participação de stakeholders relevantes.
 - Avaliação dos resultados pelos participantes: coleta de informações de uso da ferramenta, a fim de alimentar o ciclo de melhorias e desenvolvimento.
- (4) Proposta de Desenvolvimento e Implementação de Protótipos (1 estudante e 1 pesquisador):
- Protótipos de Sistemas: proposta de desenvolvimento de protótipos de sistemas de IA para diferentes aspectos da gestão de espectro, para teste e validação em ambientes controlados.
 - Testes Piloto: proposta de implementação de projetos-piloto em colaboração com operadoras e reguladores para validar a eficácia dos protótipos em cenários reais.
 - Feedback e Melhoria: proposta de coleta de feedback de testes piloto para aprimoramento contínuo das ferramentas desenvolvidas.
- (5) Workshop Meta 3 (7 estudantes e 7 pesquisadores):
- Sessão de discussões: sessão interativa para a discussão das estratégias apresentadas para a implementação de IA na gestão de espectro.
 - Palestra de especialistas: palestra sobre os desafios e oportunidades na implementação de ferramentas de IA na gestão do espectro, ministrada por especialistas.
 - Material de estudo: produção de material de educação, formação e treinamento sobre a adoção de IA na gestão do espectro.
- (6) Relatório de Análise Econômica e Benefícios a Longo Prazo (1 estudante e 1 pesquisador):
- Custo-benefício: análise do compromisso entre custo e o benefício da adoção de soluções de IA, comparando tal compromisso ao compromisso atingido com a utilização de métodos tradicionais.
 - Retorno sobre Investimento (RoI): estudo prevendo o impacto financeiro e econômico em comparação ao investimento, em curto, médio e longo prazo.
 - Projeções Futuras: projeções sobre o impacto econômico de longo prazo, considerando as alterações nas demandas e nos custos dos insumos necessários.
- (7) Proposta de Desenvolvimento de Ferramentas de Suporte (1 estudante e 1 pesquisador):
- Plataformas integradas: proposta de interfaces entre diferentes plataformas de gestão do espectro.
 - Sistemas de monitoramento: plano de desenvolvimento de sistemas para a avaliação contínua do desempenho das soluções de IA.
 - Dashboards personalizados: proposta de dashboards para acompanhamento em tempo real das soluções de IA, informando a decisão dos reguladores.
- (8) Proposta de Políticas e Normas de Governança (1 estudante e 1 pesquisador):
- Diretrizes de governança: proposta de diretrizes de governança baseadas na transparência e responsabilidade.
 - Compliance e auditoria: proposta de regras de conformidade e procedimentos de auditoria, garantindo a conformidade com normas regulatórias, padrões mínimos de qualidade e explicabilidade do modelo.
 - Ética e privacidade: proposta de diretrizes de ética e privacidade na aplicação de IA, garantindo a proteção dos dados e informações.

Meta 4 - Relatório Final com o consolidado de resultados

A Meta 4 prevê a consolidação dos resultados. A Meta 4 deverá apresentar e avaliar os modelos de IA propostos bem como seu impacto no fluxo de trabalho do regulador. Também deve avaliar os custos envolvidos, comparando-os com os benefícios. Finalmente, a Meta 4 deve ser capaz de estabelecer caminhos para o desenvolvimento futuro.

A avaliação dos modelos de IA busca compreender o compromisso entre custo e benefício dos modelos gerados. Assim, a avaliação deve considerar tanto o desempenho na correteza da execução das tarefas bem como seu desempenho computacional.

A avaliação da execução das tarefas deve ser baseada em métricas comuns na literatura científica, como acurácia, precisão e *recall*. É necessário comparar os modelos gerados com outros modelos da literatura, a fim de estabelecer expectativas a respeito de seu funcionamento.

O custo computacional dos modelos gerados deve ser utilizado para estimar a infraestrutura computacional necessária, produzindo uma estimativa de custo para a execução dos modelos. Adicionalmente, também será mapeado o tempo de execução de cada tarefa de IA.

Assume-se que o operador possui um fluxo de trabalho, composto por diversas atividades. Assim, a IA pode ser inserida como parte do fluxo do trabalho do operador, executando tarefas que auxiliam em cada atividade. Assim sendo, é necessário estimar o impacto do desempenho dos modelos de IA no fluxo de trabalho do operador. Para cada atividade desempenhada pelo regulador com auxílio de IA, devem ser estabelecidos requisitos para a IA. Por exemplo, algumas tarefas podem ser críticas e necessitar de uma alta acurácia ou *recall*. Alternativamente, algumas tarefas também críticas podem ter baixa tolerância no tempo de resposta que a IA deve oferecer. Assim, será possível compreender quais atividades do regulador podem ser auxiliadas pelos modelos de IA produzidos.

A meta 4 consistirá em um relatório único, possuindo as informações a seguir. Todos os integrantes do projeto participarão da confecção desse relatório. A divisão de responsabilidades desse relatório se dará a partir dos conceitos estudados por cada membro da equipe ao longo do projeto.

- (1) Consolidação dos resultados:
- Síntese de achados: resumo dos principais pontos do projeto e síntese das lições aprendidas ao longo do projeto.
 - Impacto das soluções: análise do impacto das soluções produzidas pelo projeto, incluindo indicadores para suportar a análise.
 - Comparação com objetivos: comparação dos resultados obtidos ao fim do projeto com os objetivos estabelecidos na proposta.
- (2) Análise de desempenho das soluções de IA:
- Avaliação de eficiência: estudo da eficiência das soluções de IA propostas, incluindo uma comparação com outras soluções disponíveis na literatura e no mercado.
 - Estudo de caso: estudo de casos específicos, com destaque para os desafios e as soluções encontradas.
 - Feedback dos stakeholders: coleta e apresentação de feedback dos stakeholders envolvidos, a fim de apontar melhorias para o futuro.
- (3) Recomendações para futuras implementações:
- Melhores práticas: estudo das melhores práticas para a implementação e adoção de IA na gestão do espectro.
 - Áreas para melhoria: identificação das áreas para melhoria contínua e sugestão para intervenção.

Roadmap futuro: apresentação de um plano detalhado de adoção de IA com ações de curto, médio e longo prazo.

(4) Documentação técnica detalhada:

Manuais de implementação: elaboração de manuais técnicos para a implementação de soluções de IA, assim como a infraestrutura computacional necessária.

Guias de usuário: elaboração de guias de usuário, a fim de que a utilização das soluções seja facilitada.

Protocolos de manutenção: elaboração de propostas de atualização e manutenção das soluções de IA, a fim do prolongamento de seu uso.

(5) Avaliação de impacto econômico e regulatório:

Análise econômica: análise do impacto econômico da adoção de soluções de IA, incluindo custos, benefícios e o retorno sobre investimento (ROI).

Impacto regulatório: análise do impacto das regulações sobre a adoção de soluções de IA, bem como recomendações para um plano de ação em caso de alterações na legislação.

Projeções futuras: projeções para o impacto econômico e regulatório da utilização de IA na gestão do espectro, considerando diferentes cenários para as telecomunicações.

(6) Apresentação de resultados e disseminação:

Relatório visual: criação de um relatório simplificado com recursos visuais, a fim de resumir de maneira interativa os resultados do projeto.

Workshop: organização de um workshop para divulgação e discussão dos resultados obtidos.

Publicações científicas: publicação de artigos em congressos e revistas, a fim de dar publicidade aos resultados do projeto, assim como de atrair a contribuição da comunidade científica.

(7) Proposta de ferramentas de avaliação e monitoramento:

Dashboards de monitoramento: proposta de dashboard de monitoramento em tempo real, possibilitando a interação do usuário com os sistemas de gestão de espectro.

Métricas de desempenho: proposta de métricas de desempenho para avaliação da adoção de soluções de IA para a gestão do espectro.

Relatórios de progresso: proposta de cronograma de relatórios sobre o progresso da implementação das soluções de IA bem como seus resultados.

(8) Estrutura de governança e sustentabilidade:

Modelo de governança: definição de um modelo de governança transparente.

Planos de sustentabilidade: definição de um plano de sustentabilidade capaz de garantir a perenidade das soluções de IA depois de sua maturação.

Políticas de atualização: definição de políticas de atualização das soluções de IA, a fim de garantir que após sua adoção e implementação seja possível garantir seu bom funcionamento.

(9) Inclusão de considerações éticas e de privacidade:

Diretrizes éticas: proposta de diretrizes de ética e privacidade na aplicação de IA, garantindo a proteção dos dados e informações.

Análise de riscos éticos: análise dos riscos éticos e desenvolvimento de estratégias para o uso adequado e responsável da IA.

REFERÊNCIAS

- Camelo, M., De Schepper, T., Soto, P., Marquez-Barja, J., Famaey, J., & Latré, S. (2020, June). Detection of traffic patterns in the radio spectrum for cognitive wireless network management. In ICC 2020-2020 IEEE International Conference on Communications (ICC) (pp. 1-6)
- Capanema, W. A. (2020). A responsabilidade civil na Lei Geral de Proteção de Dados. *Cadernos Jurídicos*, São Paulo, 2020, 21, 163-170.
- Federal Communications Commission (FCC). (2023, July 13). The Opportunities and Challenges of Artificial Intelligence for Communications Networks and Consumers. Acessível em <https://www.fcc.gov/fcc-nsf-ai-workshop>
- Kreuzberger, D., Kühl, N., & Hirschl, S. (2023). Machine learning operations (mlops): Overview, definition, and architecture. *IEEE access*, 11, 31866-31879.
- Kliks, A., Kulacz, L., Kryszkiewicz, P., Bogucka, H., Dryjanski, M., Isaksson, M., ... & Tengkvist, P. (2020). Beyond 5G: Big data processing for better spectrum utilization. *IEEE Vehicular Technology Magazine*, 15(3), 40-50.
- Kulin, M., Kazaz, T., Moerman, I., & De Poorter, E. (2018). End-to-end learning from spectrum data: A deep learning approach for wireless signal identification in spectrum monitoring applications. *IEEE access*, 6, 18484-18501.
- Mäkinen, S., Skogström, H., Laaksonen, E., & Mikkonen, T. (2021). Who needs MLOps: What data scientists seek to accomplish and how can MLOps help?. In 2021 IEEE/ACM 1st Workshop on AI Engineering-Software Engineering for AI (WAIN) (pp. 109-112). IEEE.
- Patil, A., Iyer, S., López, O. L., Pandya, R. J., Pai, K., Kalla, A., & Kallimani, R. (2024). A comprehensive survey on spectrum sharing techniques for 5G/B5G intelligent wireless networks: Opportunities, challenges and future research directions. *Computer Networks*, 110697.
- Seretis, A., & Sarris, C. D. (2021). An overview of machine learning techniques for radiowave propagation modeling. *IEEE Transactions on Antennas and Propagation*, 70(6), 3970-3985.
- Song, H., Liu, L., Ashdown, J., & Yi, Y. (2021). A deep reinforcement learning framework for spectrum management in dynamic spectrum access. *IEEE Internet of Things Journal*, 8(14), 11208-11218.
- Sun, S., Rappaport, T. S., Shafi, M., Tang, P., Zhang, J., & Smith, P. J. (2018). Propagation models and performance evaluation for 5G millimeter-wave bands. *IEEE Transactions on Vehicular Technology*, 67(9), 8422-8439.
- Venable LLP. (2023, August 4). Artificial Intelligence and the Future of Spectrum Management: FCC Adopts Notice of Inquiry on Spectrum Use Data. Acessível em <https://www.venable.com/insights/publications/2023/08/ai-and-the-future-of-spectrum-management>
- Wang, Q., Sun, H., Hu, R. Q., & Bhuyan, A. (2022). When machine learning meets spectrum sharing security: Methodologies and challenges. *IEEE Open Journal of the Communications Society*, 3, 176-208.
- Caicedo Bastidas, C. E., Stine, J. A., Rennie, A., Sherman, M., Lackpour, A., Kokar, M. M., & Schrage, R. (2018). IEEE 1900.5.2: Standard Method for Modeling Spectrum Consumption: Introduction and Use Cases. *IEEE Communications Standards Magazine*, 2(1), 49-55. <https://doi.org/10.1109/MCOMSTD.2018.1700054>.

Uma gestão eficiente do espectro radioelétrico enfrenta diversos desafios, entre os quais se destacam a ocupação eficiente e otimizada deste recurso escasso, a mitigação de interferências prejudiciais, a necessidade de flexibilidade e a adaptabilidade para se ajustar rapidamente às mudanças nas demandas de uso, e a capacitação contínua dos profissionais para lidar com tecnologias emergentes.

A aplicação de técnicas avançadas de IA pode revolucionar esse cenário, ao fornecer ferramentas robustas para previsão, alocação e monitoramento do espectro. Os modelos de IA podem ser capazes de prever a demanda futura de espectro com alta precisão, permitindo um planejamento proativo e eficiente. Além disso, algoritmos de IA podem realizar alocações dinâmicas e adaptativas de espectro, ajustando-se às mudanças na demanda e evitando a subutilização. Estas ações têm o potencial de levar a gestão do espectro a outro patamar, ao garantir o melhor uso do espectro, em tempo real, a todo tempo.

Não obstante todos os potenciais benefícios elencados, deve-se ressaltar que a implementação de IA na gestão do espectro apresenta riscos que precisam ser cuidadosamente gerenciados. A segurança dos dados é primordial, exigindo medidas robustas para proteção contra acessos não autorizados. A transparência nas decisões tomadas por sistemas de IA, além da responsabilidade pelo seu uso, também deve ser assegurada por meio de regulamentações claras e políticas de governança, sendo crucial a coordenação entre diferentes stakeholders.

Assim, a celebração deste TED para a avaliação e aplicação de soluções de IA na gestão do espectro radioelétrico no Brasil visa proporcionar melhorias significativas na eficiência e na qualidade dos serviços de telecomunicações. A adoção de soluções de IA, embora complexa, é fundamental para otimizar a previsão, alocação e monitoramento do espectro, de maneira a promover um ambiente técnico e regulatório robusto e adaptável quando da gestão dos recursos escassos.

Este TED será realizado em laboratórios do Programa de Engenharia Elétrica (PEE) da COPPE/UFRJ. Esses laboratórios serão utilizados para reuniões de acompanhamento e uso de computadores pessoais e laptops para pesquisa. Apesar de o projeto não prever a execução de experimentos práticos, os relatórios poderão ser complementados considerando o resultado de simulações e análises. Essas simulações utilizarão os servidores disponíveis nos laboratórios. Mais especificamente, será utilizada a infraestrutura do seguintes laboratórios para execução do projeto, listados em ordem alfabética:

Grupo de Teleinformática e Automação (GTA) - O laboratório do GTA possui área física total de 200 m², sala de data center, cinco salas para 20 alunos (com quatro alunos em cada sala), biblioteca, sala de reuniões e sala multimídia de 65 m² equipada com sistemas de som e câmera para videoconferências. Os recursos do laboratório GTA utilizados para o desenvolvimento do projeto consistem em equipamentos de informática, incluindo servidores biprocessados, servidores com GPUs, computadores pessoais, laptops, impressoras e equipamentos de rede.

Laboratório de Processamento de Sinais (LPS) - A infraestrutura do LPS é composta de 1 sala (310 metros quadrados) com mezanino no bloco H do Centro de Tecnologia da Escola Politécnica da UFRJ. Nesta sala encontram-se cerca de 30 computadores, sendo 10 bancadas de acesso e 20 máquinas de processamento. Nas máquinas de processamento, o laboratório conta com máquinas dedicadas a treinamento de modelos de inteligência computacional equipadas com placas de vídeo, máquinas dedicadas à inferência de modelos de inteligência computacional e máquinas de processamento de alto desempenho. Outro ponto de destaque da parte de infraestrutura do laboratório são seus equipamentos de análise de sinais, contando com um analisador de espectro Tektronix RSA5106A, um gerador de ondas arbitrarias Tektronix AWG5002 e dois osciloscópios digitais ambos da Tektronix, um TDS640A e um DPO70804.

Laboratório de Sinais Multimídia e Telecomunicações (SMT) - O SMT ocupa uma área de 310 metros quadrados e possui um amplo conjunto de equipamentos, incluindo computadores, analisadores de espectro, osciloscópios digitais, geradores de sinais, sistema de armazenamento de vídeo em tempo real, conjunto de testes de comunicações sem fio PXT, diversos sistemas de desenvolvimento de DSP, rádios definidos por software e um cluster de servidores de alto processamento, entre outros. O grupo de Sinais, Multimídia e Telecomunicações (SMT) é composto por cinco professores atuantes na graduação e na pós-graduação em tempo integral, sendo quatro Professores Titulares (dois pesquisadores 1A e dois pesquisadores 1C do CNPq) e um Professor Associado. Suas origens remontam a 1995, desenvolvido a partir do grupo de teoria de circuitos iniciado na COPPE no início dos anos setenta. Entre os tópicos de pesquisa mais importantes do SMT estão sistemas adaptativos, processamento de imagem e vídeo, processamento digital de sinais e suas aplicações, processamento de voz, processamento de áudio, comunicações sem fio, processamento distribuído, aprendizado com dados e inteligência artificial. A pesquisa nestes temas já produziu centenas de artigos em periódicos internacionais, além de diversos livros internacionais. Entre eles, destacam-se: Online Learning and Adaptive Filters, Cambridge University Press (December 8, 2022); Digital Signal Processing: System Analysis and Design, Cambridge University Press 2nd edition (September 2, 2010); e Signal Processing and Machine Learning Theory Academic Press; 1st edition (December 4, 2023).

Laboratório para o Processamento Analógico e Digital de Sinais (PADS) - o PADS possui uma sala de computadores de 70 m² conectados em rede para uso de alunos de graduação e pós-graduação, ar-condicionado, impressoras a laser, quadro, projetor data-show, sala de reuniões, TV LCD, mesas e cadeiras de escritório. Possui um servidor de rede com gerenciamento dos usuários do sistema, gerenciamento e backup de arquivos, servidor de licenças e de email. Bancada de testes de circuito integrado com multímetro, fonte, osciloscópio, analisador de rede, monocromadora, gerador de funções, ferro de solda, componentes discretos, alicates. Uma máquina para treinamento de redes neurais conectada à rede, com configuração: Microcomputador Intel Extreamer (X99M) Core i7 6850 de 3.6GHz com cooler refrigerado a água H100i, 64GB de memória DDR4/3000 Kingston Hyper X Predator, SSD M2 Samsung EVO de 1.0TB, HD WD Red de 3.0TB Sata III, 4 (quatro) Svga Geforce Gigabyte GTX1080/11GB, gabinete Corsair 780T com fonte de 1200Wts certificada.

SUBDESCENTRALIZAÇÃO

A Unidade Descentralizadora autoriza a subdescentralização para outro órgão ou entidade da administração pública federal?

- Sim
 Não

FORMAS POSSÍVEIS DE EXECUÇÃO DOS CRÉDITOS ORÇAMENTÁRIOS

A forma de execução dos créditos orçamentários descentralizados poderá ser:

- Direta, por meio da utilização capacidade organizacional da Unidade Descentralizada.
 Contratação de particulares, observadas as normas para contratos da administração pública.
 Descentralizada, por meio da celebração de convênios, acordos, ajustes ou outros instrumentos congêneres, com entes federativos, entidades privadas sem fins lucrativos, organismos internacionais ou fundações de apoio regidas pela Lei nº 8.958, de 20 de dezembro de 1994.

CUSTOS INDIRETOS (ART. 8, §2º)

A Unidade Descentralizadora autoriza a realização de despesas com custos operacionais necessários à consecução do objeto do TED?

- Sim
 Não

O pagamento será destinado aos seguintes custos indiretos, até o limite de 20% do valor global pactuado:

1. Despesas Operacionais Administrativas - DOA, Fundação COPPETEC: 10%

CRONOGRAMA FÍSICO-FINANCEIRO

| Metas | Descrição | Unidade de Medida | Quantidade | Valor Unitário | Valor Total |
|--------|--|-------------------|------------|----------------|-------------------|
| META 1 | Técnicas e abordagens de Inteligência Artificial utilizadas ou passíveis de utilização nas radiocomunicações | relatório | 1 | 76.175,20 | 76.175,20 |
| | | | | | 266.613,20 |

| CÓDIGO DA NATUREZA DA DESPESA | C |
|---|---|
| 3.3.90.18 Auxílio Financeiro a Estudantes (30 meses) | |
| 3.3.90.39.79 Outros Serviços de Terceiros (DOA) na forma de Apoio administrativo, técnico e operacional | |

Observação: O preenchimento do PAD deverá ser até o nível de elemento de despesa.

Referência: Processo nº 53500.060216/2024-35