

UNIVERSIDADE FEDERAL DE MINAS GERAIS
INSTITUTO DE CIÊNCIAS EXATAS
DEPARTAMENTO DE CIÊNCIA DA COMPUTAÇÃO

GUILHERME TRINDADE TOLENTINO BERNARDO

Orientador: Prof. Daniel Fernandes Macedo

Coorientador: Gilson Miranda Júnior

**ANÁLISE DO DESEMPENHO DE REDE SOBRE MALHAS DE
CONTROLE DE APRENDIZADO POR REFORÇO PROFUNDO NA
INDÚSTRIA 4.0**

Belo Horizonte, MG
2022

UNIVERSIDADE FEDERAL DE MINAS GERAIS
INSTITUTO DE CIÊNCIAS EXATAS
DEPARTAMENTO DE CIÊNCIA DA COMPUTAÇÃO

GUILHERME TRINDADE TOLENTINO BERNARDO

**ANÁLISE DO DESEMPENHO DE REDE SOBRE MALHAS DE CONTROLE DE
APRENDIZADO POR REFORÇO PROFUNDO NA INDÚSTRIA 4.0**

Monografia em Sistemas de Informação II apresentada ao Curso de Sistemas de Informação da Universidade Federal de Minas Gerais como parte dos requisitos necessários para a obtenção do grau de Bacharel em Sistemas de Informação.

Orientador: Prof. Daniel Fernandes Macedo

Coorientador: Gilson Miranda Júnior

Belo Horizonte, MG
2022

Bernardo, Guilherme Trindade Tolentino.

Análise do desempenho de rede sobre malhas de controle de aprendizado por reforço profundo na Indústria 4.0 / Guilherme Trindade Tolentino Bernardo. –, 2022-
27 p. 1 :il. (colors; grafs; tabs).

Orientador: Prof. Daniel Fernandes Macedo

Monografia em Sistemas de Informação II – Universidade Federal de Minas Gerais,
Instituto de Ciências Exatas, Departamento de Ciência da Computação, 2022.

1. Internet das Coisas. 2. Redes 5G. 2. Indústria 4.0. 3. Qualidade de Serviço. 4. Reinforcement Learning. 5. Ultra Reliable Low-Latency Communication I. Prof. Daniel Fernandes Macedo. II. Universidade Federal de Minas Gerais. III. Análise do desempenho de rede sobre malhas de controle de aprendizado por reforço profundo na Indústria 4.0

Agradecimentos

Aos meus pais, Frederico e Adriane, que em nenhum momento tiveram dúvidas da minha capacidade e sempre incentivaram os meus sonhos.

Ao meu irmão Enzo. Só estou aqui hoje graças a você.

As minhas avós, Eunice e Maria, que me criaram desde pequeno e moldaram meu caráter.

Ao meu orientador Daniel e ao Gilson por esse semestre de trabalho incessante e o suporte prestado para que eu conseguisse executar o trabalho.

À cada amigo e colega que conheci durante minha jornada pela universidade. Cada caractere desse trabalho tem um pouco de cada um.

À todas minhas professoras e professores do ensino básico, fundamental e médio que conseguiram me passar seu conhecimento. Professora Célia, Rose, Marta, Laila, Geovana, Gislaine Pimenta, Simone, Giovanna, Janine Viegas, Flávia Pena, Lúcia Abreu, Laís e todas as outras. Um abraço especial para o professor André que me fez apaixonar pelas ciências exatas na quinta série, ao professor Cleber que me proporcionou fascínio pela literatura e ao falecido professor Mauro Lúcio por abrir minha mente para as ciências sociais.

À cada profissional dessa universidade que me transmitiu conhecimento, e em especial, à aqueles que conseguiram cativar minha curiosidade e atenção pela matéria.

À Ele que me dá-me forças, guia-me, protege-me e orienta-me. Sempre.

Resumo

Um dos três principais casos de uso do 5G são as comunicações ultra confiáveis de baixa latência, as quais abrangem a operação de aplicações remotas para a Indústria 4.0. Espera-se que robôs autônomos, acionados por agentes de inteligência artificial rodando na nuvem, operem sem assistência humana. Esta monografia investiga como o desempenho da rede afeta o comportamento de controle autônomo remoto baseado em IA com aprendizado por reforço profundo. Investigamos dois aspectos distintos: (i) o desempenho de um modelo pré-treinado em condições ideais de rede e (ii) como as condições variáveis da rede impactam o desempenho do agente no ambiente. Os resultados mostram que a qualidade da rede impacta diretamente no desempenho do agente, e um agente pré-treinado fornece respostas melhores do que o treinamento pela rede.

Palavras-chave: Internet das Coisas, Redes 5G, Indústria 4.0, Qualidade de Serviço, Reinforcement Learning, Ultra Reliable Low-Latency Communication.

Abstract

One of the top three use cases for 5G is ultra-reliable, low-latency communications, which cover the operation of remote applications for Industry 4.0. Autonomous robots, powered by artificial intelligence agents running in the cloud, are expected to operate without human assistance. This work investigates how network performance affects AI-based remote autonomous control behavior in deep reinforcement learning. We investigated two distinct aspects: *(i)* the performance of a pre-trained model under ideal network conditions and *(ii)* how the changing network conditions impact the agent's performance in the environment. The results show that network quality directly impacts agent performance, and a pre-trained agent provides better responses than network training.

Keywords: Internet of Things, 5G networks, Industry 4.0, Quality of Service, Reinforcement Learning, Ultra Reliable Low-Latency Communication.

Lista de Ilustrações

Figura 2.1 – Aplicação para controle remoto de braço robótico (PAPCUN; ČOPÍK, 2012)	6
Figura 2.2 – Plataforma HMI para controle de impressora 3D (ARDANZA et al., 2019)	7
Figura 2.3 – Interface HMI para cortador a laser	7
Figura 2.4 – Máquina cortadora à laser	7
Figura 2.5 – Interface HMI para controle de braço robótico (ARDANZA et al., 2019)	8
Figura 2.6 – VR e AR na indústria (PAPCUN; KAJÁTI; KOZIOREK, 2018)	8
Figura 3.1 – Modelo da arquitetura de simulação da rede	12
Figura 4.1 – Recompensa média variando a latência da rede com 500.000 passos	15
Figura 4.2 – Tempo médio de conclusão da tarefa variando a latência da rede com 500.000 passos	16
Figura 4.3 – Recompensa média variando a perda de pacotes da rede com 500.000 passos	16
Figura 4.4 – Tempo médio de conclusão da tarefa variando a perda de pacotes da rede com 500.000 passos	16
Figura 4.5 – Tempo médio de conclusão da tarefa variando a corrupção do pacote de rede com 500.000 passos	17
Figura 4.6 – Recompensa média variando a corrupção de pacotes de rede com 500.000 passos	17
Figura 4.7 – Relação entre o número de timeouts e a recompensa média variando a perda de pacotes de rede com 500.000 passos	18
Figura 4.8 – Relação entre o número de timeouts e a recompensa média variando a corrupção do pacote de rede com 500.000 passos	18
Figura 4.9 – Tempo médio de conclusão da tarefa variando o jitter com 500.000 passos	19
Figura 4.10–Tempo médio de conclusão da tarefa variando a reordenação de pacotes com 500.000 passos	19
Figura 4.11–Tempo médio de conclusão da tarefa variando a latência da rede com 20.000 passos	21
Figura 4.12–Recompensa média variando a latência da rede com 20.000 passos	21
Figura 4.13–Tempo médio de conclusão da tarefa para perda de pacotes variável na rede com 20.000 passos	21
Figura 4.14–Recompensa média variando a perda de pacotes de rede com 20.000 passos	22
Figura 4.15–Variação do tempo médio	22
Figura 4.16–Variação da recompensa média	22

Lista de Abreviaturas e Siglas

IoT	Internet das Coisas (Internet of Things)
QoS	Qualidade de Serviço (Quality of Service)
URLLC	Comunicações Ultra Confiáveis de Baixa Latência (Ultra Reliable Low-Latency Communication)
RL	Aprendizado por Reforço (Reinforcement Learning)
UFMG	Universidade Federal de Minas Gerais
HMI	Interface Homem-Máquina (Human-Machine Interface)
CPS	Sistema Ciberfísico (Cyber-Physical System)
VR	Realidade Virtual (Virtual Reality)
AR	Realidade Aumentada (Augmented Reality)
UI	Interface de Usuário (User Interface)

Sumário

1	INTRODUÇÃO	1
1.1	Justificativa	2
1.2	Objetivos	2
1.2.1	Objetivo Geral	2
1.2.2	Objetivos Específicos	3
2	REVISÃO BIBLIOGRÁFICA	4
2.1	O ecossistema IoT e a evolução dos sistemas de informação	4
2.2	As redes de computadores e seus avanços tecnológicos	5
2.3	A Indústria 4.0 como cerne na transformação digital	6
2.4	Casos de uso URLLC existentes na indústria	8
2.5	Aplicações URLLC com o uso de inteligência artificial no cenário industrial	9
3	DESCRIÇÃO DO AMBIENTE DE TESTES	12
3.1	Topologia da rede simulada	12
3.2	Componentes do software	13
3.3	Metodologia de avaliação	13
4	RESULTADOS	15
4.1	Agente com pré-treino offline	15
4.2	Agente treinado na rede	20
5	CONSIDERAÇÕES FINAIS	23
5.1	Conclusão	23
	Referências	24

1 Introdução

Como humanos e robôs trabalham cada vez mais próximos em um contexto industrial (BUCHNER et al., 2012), as ferramentas de automação se tornam um diferencial no mercado ao tornar os processos produtivos mais eficientes. À medida que aplicações digitais e seres humanos se tornam mais integrados aos ambientes (HUANG et al., 2020), controlar remotamente as máquinas se tornou uma tarefa cada vez mais complexa. Logo, muito tem se falado sobre o conceito de Internet das Coisas (IoT), de forma que essa integração continue evoluindo e permitindo que mais dispositivos sejam conectados à rede. Sobretudo, a rede na qual os dispositivos estão inseridos também deve evoluir. Os avanços nos sistemas de informação permitem que os operadores da fábrica tenham informações cada vez mais atualizadas e interativas (PAPCUN; KAJÁTI; KOZIOREK, 2018). No contexto da Indústria 4.0, com mais dispositivos para coordenar, os operadores devem criar fluxos de trabalho dinâmicos que possam ser controlados por meio de uma rede. No entanto, as atuais redes móveis de 4ª geração (4G) e outras tecnologias de comunicação não podem atender às demandas da Indústria 4.0 por alta taxa de dados, alta confiabilidade, alta cobertura e baixa latência (CHENG et al., 2018). Isso dificulta o desenvolvimento e a implementação de sistemas robustos.

Atualmente, estudos em 5G Ultra Reliable Low Latency Communications (URLLC) estão abrindo caminho para o controle remoto de máquinas móveis (por exemplo, robôs, carros e drones) e reduzindo custos ao transferir a maior parte de sua inteligência para a rede (CIVERCHIA et al., 2020). Para inovar a forma como os aplicativos são controlados remotamente, pesquisadores estão usando aprendizado de máquina para estender as formas de controle tradicionais e lidar com sistemas complexos de forma integrada (HARRIS, 1994). Pode-se observar no setor industrial uma gama de aplicações que requerem controle centralizado, que utilizam algoritmos de otimização com tempos computacionais consideráveis, tornando essas soluções impraticáveis para controle em tempo real (LOBBRECHT; SOLOMATINE, 2002). Nessa perspectiva, é necessário que métodos de aprendizado de máquina sejam utilizados nessas aplicações. Assim, com a Inteligência Artificial (IA), pode-se melhorar a produtividade e o desempenho, o que é especialmente importante para uma força de trabalho remota (CONSULTING, 2020). Por exemplo, um sistema de controle remoto pode ser usado em um ambiente de trabalho hostil sem prejudicar o trabalhador, permitindo que o operador trabalhe com segurança (YANG; JIN; KWON, 2008).

Com o atual contexto de interconectividade de aplicativos, limitações severas podem ocorrer em um ambiente com centenas de dispositivos implantados na mesma fábrica em uma arquitetura de controle local, por exemplo, desafios relacionados ao controle e manutenção de vários dispositivos (NAKIMULI et al., 2021). Uma abordagem que pode superar esse problema diz respeito a migração da inteligência para servidores externos fora do dispositivo em uma

arquitetura distribuída. Dessa forma, é possível dedicar servidores exclusivos para armazenamento e processamento de dados sem sobrecarregar o sistema, uma vez que a arquitetura de controle remoto exige requisitos de entrega rigorosos para conectar diferentes ambientes. O desempenho do sistema pode ser afetado negativamente se a tecnologia de comunicação não puder atender aos requisitos de baixa latência e baixa taxa de perda de pacotes. Assim, a qualidade da rede pode afetar a decisão da IA quando executada remotamente, por exemplo, quando um pacote é perdido no tráfego de dados e o agente realiza uma ação inesperada.

Este trabalho avalia os efeitos de métricas de rede na qualidade na atuação de aplicações de controle remoto. Mais especificamente, investigamos como o desempenho da rede afeta um loop baseado em aprendizado de reforço profundo. Usamos um braço robótico como caso de uso e investigamos as variações das recompensas do aprendizado por reforço para dois casos. Primeiro, quando o aprendizado ocorre pela rede. Em segundo lugar, quando o agente é pré-treinado offline e, em seguida, implantado em uma rede. Além disso, pudemos ver que treinar um agente em condições ideais de rede é melhor do que tentar treiná-lo e usá-lo em uma rede instável. Assim, pudemos ver através do nosso simulador como a qualidade da rede afeta diretamente o controle remoto do braço robótico simulado. Conseguimos medir os impactos do atraso, reordenação de pacotes e jitter. Além disso, estabelecemos uma comparação entre as recompensas e o tempo médio para completar a tarefa usando um agente pré-treinado em condições ideais de rede contra um agente treinado online em condições de pior qualidade.

1.1 Justificativa

Com o avanço da IoT nas indústrias, inúmeros dispositivos podem ser conectados na rede podendo armazenar informações em tempo real de uma cadeia de suprimentos e executar funções operacionais variadas. Nesse contexto desafiador de interconectividade de múltiplos equipamentos nas redes de computadores, há cada vez mais investimentos voltados para a Indústria 4.0, o que faz com que haja interesse para o desenvolvimento dessa pesquisa.

1.2 Objetivos

1.2.1 Objetivo Geral

O presente trabalho tem o objetivo de desenvolver um simulador capaz de avaliar o impacto que métricas de QoS desempenham sobre as recompensas obtidas por um agente treinado em RL nas ações desempenhadas em ambientes que simulam processos físicos. O simulador permitirá que sejam testados os efeitos de novos protocolos de rede no controle remoto de aplicações URLLC.

1.2.2 Objetivos Específicos

Considerando o desenvolvimento do trabalho e o objetivo geral apresentado, destacam-se os seguintes objetivos específicos:

- Integrar ferramentas de simulação de redes com a simulação de processos físicos;
- Avaliar os resultados dos efeitos de características de QoS no desempenho de aplicações de controle;
- Realizar uma revisão da bibliografia acerca da Internet das Coisas e suas aplicações, Indústria 4.0 e as expectativas sobre o uso de redes 5G;

2 Revisão Bibliográfica

Este capítulo tem por objetivo apresentar a base teórica do uso de redes de computadores na Indústria 4.0 em relação ao atual crescimento da Internet das Coisas.

2.1 O ecossistema IoT e a evolução dos sistemas de informação

Para que os processos industriais possam alcançar a flexibilidade e eficiência, as empresas precisam de uma estrutura integrada que permita o acesso às informações do nível de produção em tempo real (SANTOS et al., 2018). Sendo assim, cada vez mais dispositivos passam a integrar as redes de comunicação da indústria, fazendo com que seja possível que os operadores consigam acessar os dados em tempo real dos equipamentos integrados. A fim de manter o nível de competitividade global, as empresas estão passando por um processo de aceleração do uso de tecnologias IoT para atender os objetivos da organização. A presença da IoT na indústria está se expandindo rapidamente, fazendo com que acadêmicos e profissionais tenham iniciado diversas pesquisas acerca do tema nos últimos anos. Além disso, o atual foco do uso de IoT na indústria tem como principal função modernizar a cadeia de suprimentos para aumentar a receita da empresa (IERA et al., 2010).

Como o setor manufatureiro influencia a economia global, as organizações agora buscam automatizar e facilitar a integração da comunicação em tempo real entre dispositivos com a ajuda de sistemas de informação (KARRE et al., 2017). Os sistemas de informação integrados a dispositivos físicos, passam a ser chamados de sistemas embarcados, ou Sistemas Ciberfísicos (*Cyber-Physical System* (CPS)) (ARRIETA; SAGARDUI; ETXEBERRIA, 2014). Um CPS é um sistema monitorado por sensor integrado com a internet que se comunica com seu usuários (KIM JUNSUNG E KIM, 2013). O CPS passa a ser utilizado cada vez mais nas cadeias produtivas industriais para monitoramento dos processos e captação de dados em tempo real para tomada de decisão gerencial. Assim, a quarta revolução industrial parece mais imperativa agora. Gestores da área industrial visam utilizar da tecnologia IoT para reinventar a cadeia produtiva e solucionar problemas corriqueiros enfrentados na linha de produção.

O desafio comum enfrentado pelos fabricantes é prever a demanda certa pela oferta, com o intuito de reduzir o tempo de produção (JOVANE et al., 2008). A tecnologia IoT supera esses desafios, o que transforma significativamente a indústria (ATZORI; IERA; MORABITO, 2010). Por exemplo, sob perspectiva da logística, esta tecnologia pode ser aproveitada para rastrear a localização de uma remessa e a velocidade de um veículo para que os usuários sejam alertados sobre atrasos nas entregas (MANAVALAN; JAYAKRISHNA, 2019). A tecnologia IoT pode ser implantada para monitorar a condição de um equipamento em um local remoto (QIU et al., 2015). Produtos sensíveis à temperatura ou sua data de validade podem ser monitorados

com sensores e os dados podem ser transmitidos através da internet. A confluência de internet sem fio e armazenamento de dados em nuvem podem mudar todas as operações da cadeia de abastecimento da indústria e trazer mais valor com isso (YANG WU, 2011). Perdas podem ser minimizadas usando IoT, pois há o monitoramento atual da situação da linha produtiva e envio do status para as partes interessadas (ACCORSI et al., 2017).

2.2 As redes de computadores e seus avanços tecnológicos

A evolução das redes pode ser vista em um trabalho que inicia-se na década de 80, na introdução da tecnologia de redes móveis com o 1G. Utilizada nos primeiros celulares, a transmissão na rede 1G funcionava de forma analógica, utilizando sinais de rádio para codificar o áudio, e a tecnologia era limitada a fornecer os serviços de voz entre aparelhos (MAGALHAES, 2021). Com a atual chegada das redes 5G, há um suporte de conexão para muito mais dispositivos na rede com uma velocidade significativamente mais rápida. Picos de taxas de dados esperada de 10 Gbps e alta taxa experimentada pelo usuário em 100 Mbps são possíveis com o 5G (AMARAL, 2015). Hélio Oyama, diretor de *product management* na *Qualcomm LATAM*, comenta em uma entrevista dada à revista Forbes que mais dispositivos conectados, maior transmissão de dados à latência dez vezes inferior quando comparada com redes 4G e cinco vezes maior velocidade de conexão (CARMEN, 2021) são características que possibilitarão maior controle de aplicações remotamente, uma vez que o 5G caracteriza-se como uma rede móvel. Sob uma ótica técnica, para que a interface homem-máquina (*Human Machine Interface*, (HMI)) seja estabelecida em uma rede estável, deve-se avaliar os efeitos que a QoS desempenha no controle dessas aplicações de controle remoto.

Ao se falar de redes de computadores, pode-se avaliar os impactos de QoS em redes sem fio (*wireless*) e com fio. Entretanto, em uma perspectiva de automação industrial com a utilização de robôs para controle remoto, acionamentos à distância são mais condizentes com as redes *wireless*. As redes de sensores sem fio mostram-se eficazes para alcançar a IoT em ambientes industriais, tendo sido alvo de pesquisas recentes (LU et al., 2016). O *wireless* permite que usuários se conectem facilmente por meio de dispositivos móveis, podendo simplificar a linha de produção e economizar custos com deslocamento de mão de obra. Várias tecnologias de comunicação sem fio estão sendo aplicadas em IoT, sendo elas para curta distância, como Wi-Fi, Zigbee e Bluetooth, ou para longa distância, como 3G, 4G e 5G (CHENG et al., 2018). Entretanto, para o contexto de HMI na Indústria 4.0, as tecnologias de comunicação sem fio de pequenas áreas não são adequadas para a ampla gama de dispositivos conectados na rede. Além disso, as métricas de QoS das atuais tecnologias de comunicação *wireless* de longa distância não são suficientes para atender as demandas futuras da IoT.

2.3 A Indústria 4.0 como cerne na transformação digital

Todos os conceitos que tangem as aplicações de ferramentas de automação na Indústria 4.0 possuem influência direta na HMI. Diversos estudos publicados tratam da evolução da HMI e como a interação com as máquinas impactaram diretamente a indústria durante as últimas décadas. [Papcun e Čopík \(2012\)](#) estudaram o comportamento do controle remoto de um braço robótico industrial Mitsubishi MELFA RV-2SDB (Fig. 2.1). Foi feito um estudo sobre o controle deste robô através de telefone inteligente com sistema operacional *Android* e foi constatado que algumas tarefas relacionadas à HMI, como ensinar ao robô uma sequência parametrizada de movimentos, não pode ser concluída com êxito devido a alta necessidade de transmissão de dados demandada por esse tipo de serviço.



Figura 2.1 – Aplicação para controle remoto de braço robótico ([PAPCUN; ČOPÍK, 2012](#))

A HMI surge como uma ferramenta inovadora e estratégica para construir ambientes interativos entre humanos e robôs com segurança ([VYSOCKY; NOVAK, 2016](#)). Robôs industriais, por exemplo, são amplamente utilizados nas empresas, substituindo tarefas humanas perigosas, repetitivas, de difícil processamento ou com maiores complexidades analíticas ([ROBLA et al., 2017](#)). Assim, a utilização de um ferramental que aprimore a interação homem-máquina, como a tecnologia 5G em redes de computadores, pode ser observada em diferentes cenários na indústria.

Espera-se que o 5G integre várias tecnologias de comunicação para suportar casos de uso para comunicações ultra confiáveis de baixa latência (*Ultra Reliable Low-Latency Communications* (URLLC)). Existem diversas estratégias diferentes para utilizar várias interfaces simultaneamente e alcançar alta confiabilidade e baixa latência ([NIELSEN; LIU; POPOVSKI, 2018](#)). Assim, essas estratégias possibilitam a introdução de interfaces homem-máquina avançadas, flexíveis e adaptáveis das quais proporcionarão aos operadores informações e ferramentas personalizadas para serem mais produtivos de forma mais segura. Alguns exemplos de interfaces próprias para a Indústria 4.0 são analisados em diversas pesquisas. [ARDANZA et al. \(2019\)](#) propuseram um caso de uso sobre a HMI em impressoras 3D, uma vez que são vistas como uma

tendência tecnológica em manufatura. O objetivo do caso de uso era criar uma HMI customizada para uma impressora 3D existente (Fig. 2.2).



Figura 2.2 – Plataforma HMI para controle de impressora 3D (ARDANZA et al., 2019)

A plataforma fornece conectividade bidirecional ao adicionar uma nova interface de usuário (UI) para navegação e mais controle da máquina. Além disso, a plataforma permite imprimir peças diretamente, enviando os comandos apropriados para a impressora iniciar o processo de impressão (ARDANZA et al., 2019). Uma grande vantagem dessa UI é a redução do desperdício de material e consumo energia. A longo prazo, há a economia de tempo de impressão não útil, o que aumenta o desempenho geral da impressora 3D.

Um outro exemplo prático observado pelo estudo foi a utilização de uma HMI (Fig. 2.4) para controle em tempo real de motores de um cortador a laser (Fig. 2.3). Os testes da pesquisa mostraram que a HMI pode ser usada não apenas para exibir dados ao usuário, mas também como controle em tempo real de maquinário industrial (ARDANZA et al., 2019).



Figura 2.3 – Interface HMI para cortador a laser

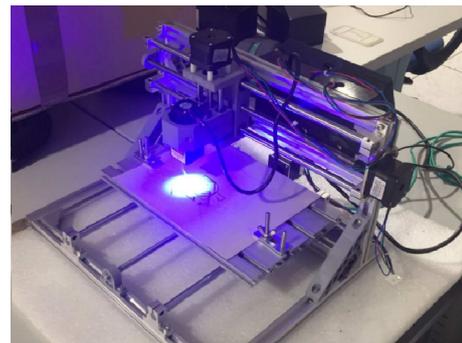


Figura 2.4 – Máquina cortadora à laser

O atraso entre a máquina e os comandos de controle da interface são insignificantes em comparação com a velocidade e precisão do cortador a laser. Um caso de uso prático no uso de uma interface homem-máquina no cenário industrial pode ser observado na visualização de uma virtualização 3D interativa de um braço robótico, recebendo informações em tempo real de suas articulações (Fig. 2.5).

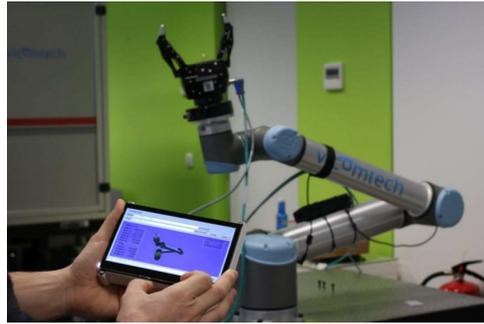


Figura 2.5 – Interface HMI para controle de braço robótico (ARDANZA et al., 2019)

Uma visualização 3D interativa do braço robótico fornece melhores informações cognitivas. Os resultados mostram que a HMI pode lidar com a visualização interativa 3D quase em tempo real do braço robótico, além de conseguir monitorar com sucesso o processo de digitalização de peças industriais para a Indústria 4.0 (ARDANZA et al., 2019).

2.4 Casos de uso URLLC existentes na indústria

Os avanços nos sistemas de informação permitem que os operadores de uma fábrica tenham informações cada vez mais atualizadas e interativas (PAPCUN; KAJÁTI; KOZIOREK, 2018). Ferramentas como a realidade virtual (*Virtual Reality* (VR)) e a realidade aumentada (*Augmented Reality*, (AR)) em conjunto com a utilização de robôs nas plantas industriais possibilitam o desenvolvimento de um espaço inteligente e informatizado (Fig. 2.6).



Figura 2.6 – VR e AR na indústria (PAPCUN; KAJÁTI; KOZIOREK, 2018)

Um cenário típico para a aplicação de uma rede 5G para a Indústria 4.0 é na otimização da produção manufaturada e heterogênea no chão de fábrica (CHENG et al., 2018). Com as aplicações de automação em chão de fábrica, a otimização das linhas de produção em larga escala mostram-se necessárias. Por um lado, o processo de fabricação de um produto envolve uma série de subprocessos e diferentes equipamentos de fabricação da linha de produção que são responsáveis por diferentes tarefas. Há uma necessidade de que essas tarefas de processamento sejam executadas de maneira ordenada, colaborativa e na hora certa. Graças à essa multiplicidade de solicitações e à limitação da estrutura mecânica, um único robô não consegue realizar algumas

tarefas complicadas, como montagem e soldagem de maneira coordenada. Além disso, alguns cenários de manufatura estão inseridos em ambientes hostis que, por muitas vezes, requerem o controle remoto para realização de tarefas que exijam a cooperação de mais de um robô. Esses cenários de fabricação requerem uma transmissão precisa e latência muito baixa para a transmissão bidirecional dos dados (CHENG et al., 2018).

Esse modelo de aplicação sinérgica URLLC entre homem-máquina, não só melhora a eficiência da produção, mas torna o sistema produtivo mais robusto e flexível. Ao mesmo tempo, as tecnologias de comunicação de alta confiabilidade e baixa latência como o 5G são necessárias para garantir segurança e uma HMI eficaz. Ao analisar o URLLC como um serviço de comunicação para entrega de pacotes com sucesso seguindo requisitos rigorosos, como disponibilidade, latência e confiabilidade, o serviço URLLC irá alavancar a automação industrial com uma comunicação em rede mais eficiente e segura (LI et al., 2018). Os sistemas 5G emergentes precisarão dar suporte de forma eficiente ao tráfego consequente da utilização de aplicações URLLC na indústria (POPOVSKI et al., 2019). Sendo assim, a comunicação ultra-confiável inevitavelmente se tornou uma parte dos sistemas *wireless* 5G emergentes por se destinar a aplicações com requisitos de latência muito rigorosos, como comunicação entre máquinas e robôs nos casos de uso da Indústria 4.0. Kalør et al. (2017) discorrem sobre o papel importante que a tecnologia 5G, e particularmente os serviços URLLC, desempenharão na transformação dos sistemas de manufatura industrial na Indústria 4.0. Com os atuais avanços no tema, uma ampla gama de novos aplicativos surgirão devido ao aumento da conectividade.

2.5 Aplicações URLLC com o uso de inteligência artificial no cenário industrial

A tecnologia IoT está sendo amplamente utilizada nas indústrias (ATZORI; IERA; MORABITO, 2010). As aplicações industriais exigem velocidades de transmissão muito altas e são extremamente sensíveis a atrasos na rede. Em aplicações de malha de controle fechada, intertravamento, monitoramento e supervisão, há atrasos toleráveis na faixa de milissegundos (AKPAKWU et al., 2017; ETSI, 2020). No entanto, é possível expandir a análise da aplicação da IoT para outras áreas além da indústria. Esses aplicativos, conhecidos em 5G como URLLC, têm latência e jitter como as duas principais métricas de QoS a serem observadas (NASRALLAH et al., 2018). Como delay e jitter são as métricas de QoS mais importantes para serviços em tempo real (KUNST et al., 2019), elas merecem atenção especial ao avaliar o desempenho da solução proposta. No trabalho de Kunst et al. (2019), os autores mantiveram valores de jitter entre 25 ms e 47 ms, levando a concluir que a aplicação utilizada foi capaz de garantir QoS considerando as métricas de atraso e jitter. Chen, Farley e Ye (2004) propuseram medidas numéricas que podem representar quantitativamente os requisitos de QoS de várias aplicações com diferentes características de serviço, concluindo que não pode haver erro e perda de dados críticos ao controlar um

processo industrial importante. [Rodriguez et al. \(2021\)](#) apresentaram uma estrutura experimental que consiste no uso e otimização de desempenho de robôs móveis autônomos integrados ao 5G. Eles usaram ferramentas de prototipagem que consistem em um sniffer de tráfego de rede, um emulador 5G e um gateway de multiacesso sem fio. Por motivos de mobilidade, robôs móveis autônomos são elementos nativos sem fio. Quando eles aplicaram essa estrutura, eles focaram no controle geral de 5G dos robôs e na operação de nuvem do robô através do 5G. Eles puderam ver que a operação 5G dos robôs era superior em termos de confiabilidade do loop de controle à do Wi-Fi 6 e o potencial do 5G para a expansão da utilização de robôs móveis autônomos com operações confiáveis.

[Marques et al. \(2018\)](#) analisaram e apresentaram o impacto das redes definidas por software e tecnologias de computação em nuvem para sistemas que executam aplicativos em tempo real com baixa latência de ponta a ponta e altos requisitos de largura de banda. Assim, para alcançar a URLLC em redes sem fio para suportar a mobilidade de robôs, eles propuseram e implementaram uma divisão das funcionalidades da arquitetura WiFi de forma a oferecer multiconectividade e comunicação redundante, possibilitando uma mobilidade perfeita e resiliência de *failover*. Eles mostraram que o robô não perde a comunicação com a nuvem, e a degradação do controle é muito pequena se comparada aos resultados obtidos com processos clássicos na utilização de uma rede Wi-Fi. Assim, os resultados mostram que a arquitetura apresenta um bom desempenho na recuperação a falhas, sendo capaz de garantir a comunicação a qualquer momento.

Nessa mesma ótica, [Liberato et al. \(2018\)](#) propuseram uma arquitetura de rede usada para facilitar e aprimorar a programabilidade da rede, que é um importante facilitador para redes 5G. Eles argumentaram que, em comparação com a tecnologia 4G de rede, espera-se que o 5G forneça 100 vezes aumento na taxa de transferência e no número de dispositivos conectados por metro quadrado, enquanto a latência deve ser reduzida de 30 a 50 vezes, especialmente para clientes URLLC. Como resultados, seu protótipo demonstrou que a arquitetura de rede definida é capaz de oferecer proteção de nível de operação que alcança a comunicação ultra-confiável com sub-milissegundos para recuperação de falhas, que é um caso de uso importante na Indústria 4.0, uma vez que aplicações industriais exigem níveis muito rígidos de qualidade de rede.

O uso de um sistema remoto de IA para controlar Veículos Guiados Automatizados (AGV) é outra aplicação em que a comunicação é crucial. [Nakimuli et al. \(2021\)](#) realizaram vários experimentos para investigar todos os cenários viáveis para implantar um AGV controlado remotamente usando 5G. Seus resultados mostram a viabilidade do uso do 5G como tecnologia de comunicação móvel para interligar o AGV com o controlador virtualizado. Eles também forneceram evidências do desempenho aprimorado de 5G sobre 4G por meio da plataforma 5G EVE, que é uma instalação 5G de ponta a ponta atualmente usada por indústrias verticais para executar e validar seus casos de uso por meio de medições de KPI. Essa plataforma foi útil para investigar todos os cenários viáveis para implantar um caso de uso de AGV controlado remotamente usando 5G. Portanto, os resultados ilustram a tolerância do sistema a perdas e atrasos

de pacotes. Além disso, quando comparado à condição de rádio 4G, o caso de uso utilizando 5G apresentou um melhor controle do AGV em sua trajetória mesmo com perdas de pacotes e atrasos citados.

Al-Turjman et al. (2019) usaram algoritmos genéticos para determinar a posição ideal para estações base de drones 5G, dadas as restrições de cobertura, energia e custo. Assim, eles visavam melhorar parâmetros como a taxa de dados, latência e taxa de transferência. Os autores concluíram que o uso de algoritmos genéticos pode fornecer melhores resultados em tempo hábil para aplicações críticas de veículos aéreos não tripulados externos, visando uma nova tendência na cobertura 5G. Por sua vez, Beltrão e Pires (2019) propõem um estudo de caso em uma caldeira de recuperação de carvão de uma fábrica de celulose, em que é analisada a aplicação de drones combinados com inteligência artificial e computação em nuvem para inspeção visual. Assim, o drone foi capaz de realizar a inspeção visual na indústria de celulose de forma autônoma, entregando imagens e vídeos de altíssima resolução de estruturas que precisam de uma inspeção periódica de rotina, como tanques de armazenamento, vasos de pressão e caldeiras de carvão de maneira fácil de interpretar e com mais detalhes. Concluíram que essa tecnologia reduz drasticamente a exposição dos trabalhadores a riscos de acidentes, agiliza a operação de campo e gera melhorias nos processos de gestão de ativos.

Para planejar a infraestrutura de rede 5G, Yu, Lee e Jeon (2017) analisaram cenários de serviço detalhados para redes móveis e categorizou suas características em relação aos requisitos técnicos tanto para a comunicação da rede sem fio quanto para os lados da rede principal. Eles propuseram requisitos potenciais para cada grupo de casos de uso relacionados a indústrias, por exemplo, latência de ponta a ponta, densidade de tráfego e taxa de dados experimentada pelo usuário em aplicativos URLLC para a indústria. Os resultados mostram que os requisitos propostos podem ser usados como diretriz na padronização, implementação e implantação de redes 5G.

Até onde sabemos, esta monografia consiste como o primeiro estudo na literatura que tenta entender os efeitos do desempenho da rede em uma aplicação URLLC do ponto de vista dos algoritmos de inteligência artificial. Trabalhos anteriores tentaram fornecer valores máximos e mínimos para métricas de rede que garantem o funcionamento das aplicações. Este trabalho, por outro lado, quantifica a quantidade de degradação na malha de controle inteligente para cada métrica de rede. Assim, neste trabalho mostramos quantitativamente a comparação de desempenho de agentes treinados online e offline, tanto do ponto de vista do aprendizado de máquina, ao analisar as recompensas do loop agente-ambiente obtidas, quanto do ponto de vista do usuário final da aplicação, ao analisar o tempo médio para o agente atingir seu objetivo.

3 Descrição do ambiente de testes

Neste trabalho, foi desenvolvido um simulador para avaliar os efeitos que a QoS exerce no controle remoto de aplicações simuladas. O simulador desenvolvido considera tanto o lado da aplicação quanto o lado da rede. A descrição do simulador, bem como a metodologia experimental é apresentada a seguir. O simulador é um software de código aberto¹.

3.1 Topologia da rede simulada

As ações do agente no cliente devem percorrer a rede até chegar ao servidor onde está localizado o ambiente. Quanto melhor a rede para o transporte de informações, menos erros devem ser observados no desempenho do agente. Os agentes utilizados no simulador baseado em RL realizam ações nos ambientes, nos quais servem como ferramenta para simular ações de um usuário ou sistema de controle em um equipamento ou aplicativo remoto. A cada passo, o agente escolhe uma ação e o ambiente retorna uma recompensa (Fig 3.1). Para enviar ações do agente pela rede, usamos pacotes UDP.

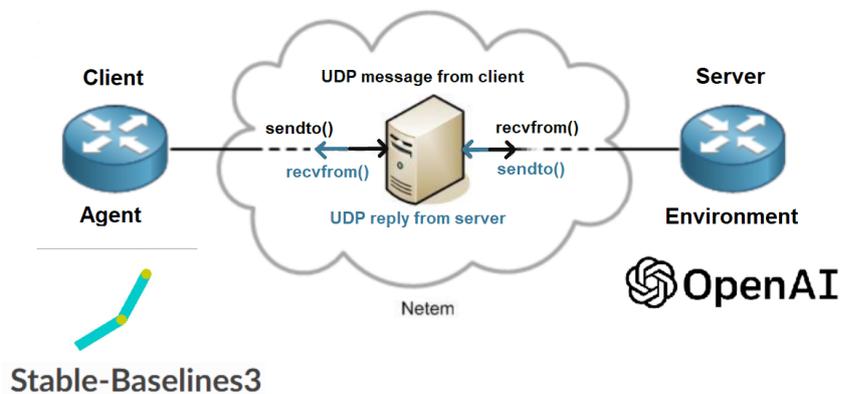


Figura 3.1 – Modelo da arquitetura de simulação da rede

Para avaliar o desempenho do agente no primeiro cenário, consideramos uma latência de 1 ms a 50 ms, uma vez que aplicações de controle industrial possuem limites de atraso de até um milissegundo (ETSI, 2020). Kunst et al. (2019) manteve valores de jitter entre 25 ms e 47 ms, então usamos no simulador um valor limite para garantir que a QoS seja de 50 ms. Neste trabalho, consideramos uma taxa de limiar $\leq 1\%$ para perda e corrupção de pacotes, conforme Chen, Farley e Ye (2004) representaram quantitativamente os requisitos de QoS de várias aplicações.

Para alterar as métricas de QoS utilizamos o Linux Network Emulator (NetEm), que é uma funcionalidade para testar protocolos emulando as propriedades de redes de longa distância. Foi

¹ <<http://github.com/gmj93/CASim.git>>

possível simular diferentes valores de latência, jitter, perda de pacotes, corrupção e reordenação. No simulador, os parâmetros definidos pelo NetEm permaneceram constantes durante os testes.

3.2 Componentes do software

Para criar uma aplicação industrial, usamos os ambientes do OpenAI Gym, que é um kit de ferramentas para desenvolver e comparar algoritmos em RL. Esses ambientes são usados para avaliar o desempenho de agentes treinados com algoritmos da biblioteca Stable Baselines 3. Esta biblioteca implementa uma série de problemas de controle, como problemas de brinquedos adequados para RL, jogos de vários níveis de complexidade, bem como muitos robôs e braços robóticos que simulam aplicações industriais (RAFFIN et al., 2021).

A aplicação simulada de Indústria 4.0 consiste em executar o ambiente Acrobot-v1, um problema clássico em RL descrito pela primeira vez por Richard Sutton em 1996. O ambiente Acrobot-v1 do OpenAI Gym simula um braço mecânico com dois segmentos e duas articulações, onde o objetivo é mover o articulações para que a parte inferior do braço atinja uma certa altura. No Acrobot-v1, um episódio termina quando o braço robótico atinge a linha-alvo ou quando o limite de tempo para atingir a linha-alvo é extrapolado. Este ambiente foi escolhido devido à semelhança com aplicações da Indústria 4.0, como o acionamento remoto de um braço robótico pick-and-place. Porém, nosso simulador permite a utilização de qualquer ambiente implementado no OpenAI Gym.

Utilizamos o algoritmo Advantage Actor Critic (A2C) para treinar o agente tanto no ambiente de treinamento online quanto para o agente pré-treinado (SIMONINI, 2018). A2C é um algoritmo de aprendizado de reforço profundo, que é um método RL híbrido baseado em valor (por exemplo, *Q-learning*, *Deep Q-learning*) e em métodos baseados em políticas (por exemplo, aprendizado por reforço com políticas de gradiente). Esse método usa duas redes neurais para medir quão boa é a ação tomada (baseada em valor) e um ator que controla como o agente se comporta (baseado em política). Escolhemos esse método porque não precisamos esperar até o final do episódio para calcular a recompensa, o que precisaria de muitas amostras e levaria muito tempo para convergir com aprendizado lento. Além disso, o A2C não disfarça ações ruins, pois fazemos uma atualização a cada etapa. Assim, ao final de um episódio, teremos a recompensa total que leva em consideração cada ação do agente no ambiente.

3.3 Metodologia de avaliação

Este trabalho tem como objetivo investigar como os parâmetros de QoS da rede afetam o treinamento e a execução de malhas de controle RL em aplicações da Indústria 4.0. Para tanto, criamos dois cenários de avaliação: um onde o agente é treinado em condições ideais de rede e outro cenário onde o treinamento do agente ocorre na rede.

- **Cenário #1: treino offline.** O primeiro cenário poderia ser usado em um sistema de inteligência artificial que pode ser treinado offline na nuvem. Após a implantação, o agente é instalado no dispositivo IoT e operado na nuvem. Este pode ser o caso de diferentes aplicações da Indústria 4.0 (por exemplo, controle de braço robótico *pick-and-place*) onde as tarefas são imutáveis ao longo do tempo.
- **Cenário #2: treino na rede.** O segundo cenário trata de situações em que é necessário treinamento contínuo, para trabalhar bem com os atrasos e perdas de uma rede real. Um exemplo é uma linha de produção de ferramentas automotivas, onde as peças que estão sendo construídas mudam o tempo todo: apenas algumas unidades de cada ferramenta são produzidas, e então a linha assume outro projeto.

Para os testes de QoS, os agentes são treinados com o mesmo número de passos e o mesmo ambiente foi utilizado para avaliar apenas o impacto da modificação na rede no desempenho do agente.

Métricas de avaliação. Usamos os mesmos agentes para avaliar como a qualidade da rede afeta não apenas a recompensa total sob uma perspectiva de aprendizado de máquina, mas o tempo médio que o agente precisa para concluir sua tarefa. A recompensa média é calculada pela média aritmética das recompensas, que corresponde ao número de ações realizadas pelo agente durante um episódio, obtido ao final de cada um dos 100 episódios avaliados. Para cada ação bem-sucedida do agente, o ambiente retorna uma recompensa de -1 ponto. No final do episódio, obtemos a recompensa total por completá-lo. No segundo cenário, comparamos cada métrica com a recompensa média obtida com o agente pré-treinado. Também calculamos um intervalo de confiança de 95% das recompensas obtidas ao final de cada episódio.

- Um intervalo de confiança é um intervalo usado para estimar o tamanho provável de um parâmetro populacional, servindo como medida do grau de confiabilidade dos dados (MCLEOD, 2019). Os níveis de confiança mais usados são os intervalos de confiança 90%, 95% e 99% que possuem probabilidades de 0,90, 0,95 e 0,99 respectivamente de conter o parâmetro. Para o parâmetro de população μ , intervalo de confiança de 95% ($\hat{\mu}_L, \hat{\mu}_U$) of μ é um intervalo que satisfaz

$$P(\hat{\mu}_L \leq \mu \leq \hat{\mu}_U) = 0.95.$$

- Como o simulador nos dá o desvio padrão (σ) das recompensas obtidas ao final dos episódios ($n = 100$), podemos dizer que o intervalo de confiança para μ é

$$\hat{\mu}_L = \bar{x} - z_{\alpha/2} \cdot \sigma / \sqrt{n}, \quad \hat{\mu}_U = \bar{x} + z_{\alpha/2} \cdot \sigma / \sqrt{n},$$

onde o quantil $z_{\alpha/2}$ é dado por $P(Z > z_{\alpha/2}) = \alpha/2$. Neste trabalho usamos um intervalo de confiança de 95% para μ , que é

$$\hat{\mu}_L = \bar{x} - 1.96 \cdot \sigma / \sqrt{n}, \quad \hat{\mu}_U = \bar{x} + 1.96 \cdot \sigma / \sqrt{n}.$$

4 Resultados

Os gráficos abaixo permitem comparar o desempenho no tempo e no número de ações realizadas para cada variação de cada métrica de QoS. Além disso, conseguimos estabelecer comparações entre as métricas ao analisar os dados, de modo que pudemos inferir que para um mesmo agente pré-treinado, a piora da qualidade da rede afeta negativamente seu desempenho.

4.1 Agente com pré-treino offline

Latência: A latência de uma rede, medida em milissegundos (ms), define quanto tempo uma solicitação leva para ser transferida de um ponto a outro. Sem fazer alterações na QoS da rede entre cliente e host, foi observada uma latência média de ≤ 1 ms nas primeiras 10 requisições. Como esperado, recompensas menores podem ser vistas à medida que a latência da rede aumenta consideravelmente (Fig. 4.1). Assim, quanto maior a latência da rede, maior a dificuldade do agente em executar as ações com sucesso, o que resulta em um tempo maior para atingir o objetivo (Fig. 4.2).

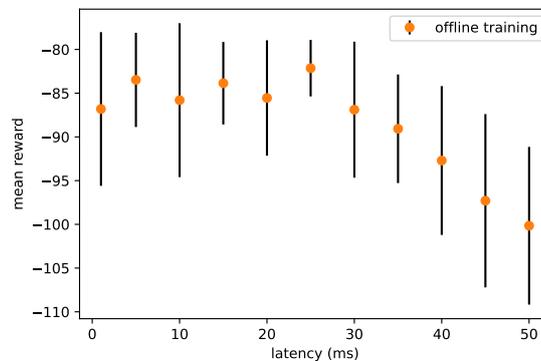


Figura 4.1 – Recompensa média variando a latência da rede com 500.000 passos

Após aumentar o atraso acima de 30ms de latência, o desempenho geral dos agentes fica muito ruim. Percebe-se que o tempo médio em cada episódio cresce consideravelmente à medida que a latência da rede aumenta. Também pode ser visto que a curva cai consideravelmente para uma recompensa de -100 pontos para o ambiente Acrobot-v1.

Perda de pacotes: À medida que a taxa de perda de pacotes aumenta, ocorrem timeouts na comunicação entre o agente e o ambiente. Isso ocorre porque pacotes que indicam o fim de um episódio podem ser perdidos durante o tráfego, fazendo com que o agente não receba a recompensa pelo ambiente. Nesses casos, o braço robótico fica estático. O simulador então força o episódio a continuar reenviando o pacote, para que o ambiente ainda o receba, mesmo que atrasado.

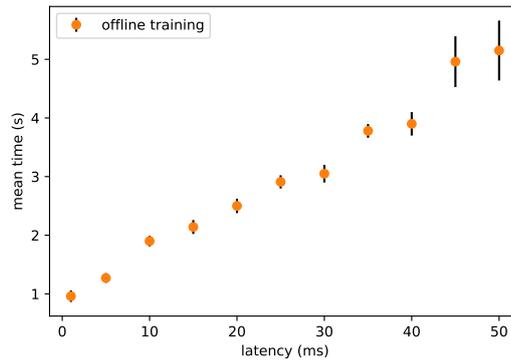


Figura 4.2 – Tempo médio de conclusão da tarefa variando a latência da rede com 500.000 passos

Com este teste, foi possível verificar que com 1% de perda de pacotes, em 94% dos episódios ocorreu timeout. Assim, podemos ver na Figura 4.3 e na Figura 4.4 a recompensa média e o tempo médio respectivamente obtidos pelo agente à medida que aumentamos a taxa de perda de pacotes.

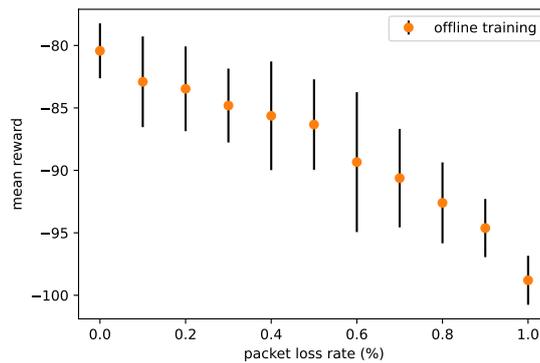


Figura 4.3 – Recompensa média variando a perda de pacotes da rede com 500.000 passos

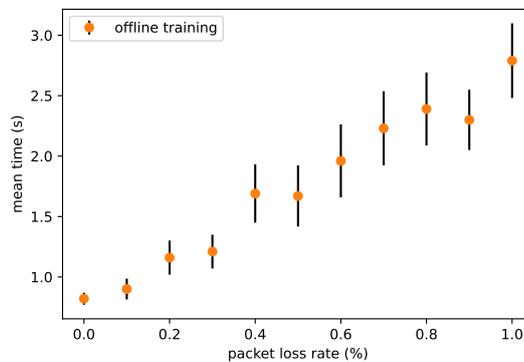


Figura 4.4 – Tempo médio de conclusão da tarefa variando a perda de pacotes da rede com 500.000 passos

Observe que o tempo médio aumenta consideravelmente devido ao número de timeouts que ocorrem à medida que a qualidade da rede se deteriora. Assim, a recompensa média dos episódios tende a diminuir e se tornar mais instável, o que pode ser percebido por intervalos de confiança maiores. Isso ocorre porque a rede fica instável com muitas perdas de pacotes e as solicitações são perdidas. Dessa forma, o comportamento do agente também fica instável, necessitando de mais ações e demorando mais para completar o objetivo. Isso mostra que se algum pacote contendo a informação de que o episódio chegou ao fim for perdido, como a seleção dos pacotes que serão perdidos é arbitrária com o NetEm, a aplicação torna-se inviável para controle remoto.

Corrupção de pacotes: Analogamente a outras métricas de QoS, quanto pior a qualidade da rede, mais difícil é controlar remotamente o braço robótico (Figura 4.5). Ao avaliar a corrupção, uma taxa de 1% retornou uma recompensa média de -89,22 pontos, que é 7,35% pior do que os -82,66 pontos obtidos com uma taxa de corrupção de 0,1%. Também podemos ver que enquanto o tempo para completar um episódio aumenta à medida que a taxa de corrupção de pacotes aumenta, a recompensa obtida no final de cada episódio diminui (Figura 4.6).

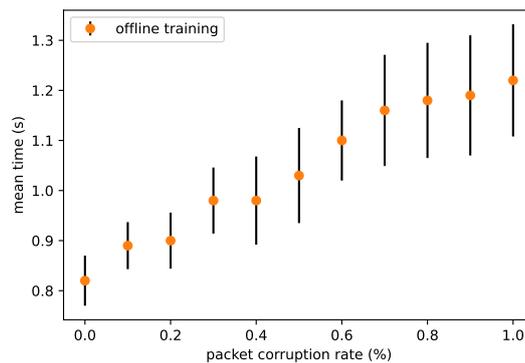


Figura 4.5 – Tempo médio de conclusão da tarefa variando a corrupção do pacote de rede com 500.000 passos

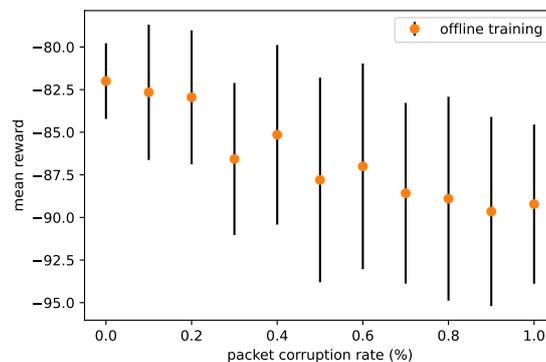


Figura 4.6 – Recompensa média variando a corrupção de pacotes de rede com 500.000 passos

Uma vez que o agente retoma a execução de suas ações a partir da posição em que parou antes da ocorrência de timeouts, o número de ações não aumenta necessariamente à medida que mais exceções de tempo ocorrem na rede. Portanto, para penalizar o grupo de episódios em que mais exceções ocorreram, relacionamos diretamente o número de timeouts ao valor final da recompensa. Desta forma, a Figura 4.7 relaciona a recompensa média obtida ao final dos 100 episódios com o número de exceções de timeouts que ocorreram. Assim, podemos ver na Figura 4.8 que correlacionando o número de ocorrências de timeouts é claramente possível ver como a piora na qualidade da rede afeta o desempenho geral do agente.

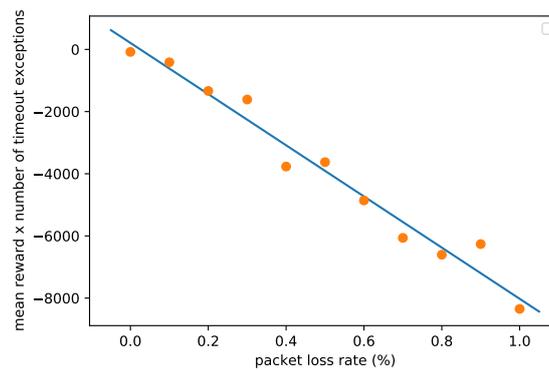


Figura 4.7 – Relação entre o número de timeouts e a recompensa média variando a perda de pacotes de rede com 500.000 passos

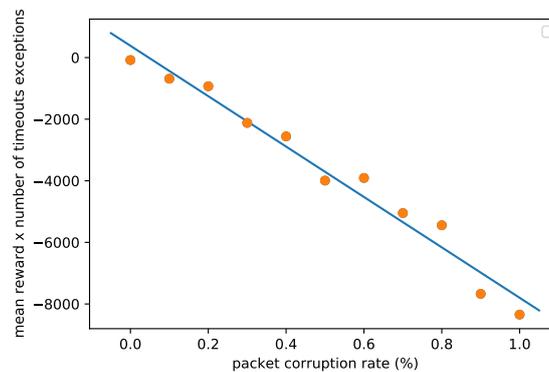


Figura 4.8 – Relação entre o número de timeouts e a recompensa média variando a corrupção do pacote de rede com 500.000 passos

Jitter: O jitter é uma variação estatística do atraso na entrega de dados em uma rede. Assim, o simulador realiza a variação do atraso entre sucessivos pacotes de dados em uma rede. Essas pequenas variações na latência entre a entrega de pacotes separados podem ser causadas por congestionamento de rede, colisões de rede ou interferência de sinal. Por padrão, os parâmetros de atraso são descritos pelo valor médio (μ) e desvio padrão (σ). Por padrão, O NetEm usa uma distribuição uniforme, de modo que o atraso esteja dentro de $\mu \pm \sigma$. Para os testes, foram considerados jitters de 5ms, 10ms, 15ms e 20ms. Portanto, todos os pacotes que saem do host

sofrerão um atraso, com uma variação aleatória de jitter. Na Figura 4.9 podemos ver que quando o jitter da rede é de 20 ms, o tempo médio para completar o episódio é relativamente maior.

Reordenação de pacotes: A reordenação de pacotes é um fenômeno bem conhecido em que a ordem dos pacotes é invertida dentro de uma rede. Para avaliar o comportamento do agente com base nessas variações estatísticas de atraso na entrega de pacotes, foi possível simular, por exemplo, o envio imediato de 25% dos pacotes e os demais com atraso de 50 ms, o que é mais como na vida real, porque faz com que uma certa porcentagem dos pacotes seja mal ordenada. O caso de teste que mais impactou o controle remoto da aplicação, com exceção do caso em que nenhum pacote é enviado imediatamente, foi o envio dos primeiros 25% pacotes primeiro e depois o atraso dos demais. A Figura 4.10 mostra que, à medida que aumentamos a taxa de envio imediato, o tempo que o agente leva para atingir a meta diminui significativamente, pois menos pacotes serão atrasados na rede.

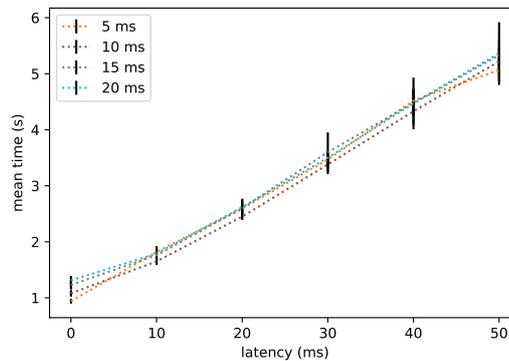


Figura 4.9 – Tempo médio de conclusão da tarefa variando o jitter com 500.000 passos

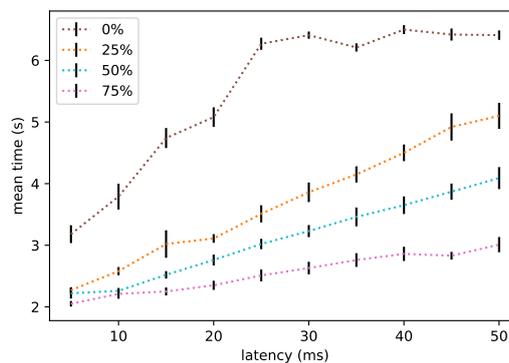


Figura 4.10 – Tempo médio de conclusão da tarefa variando a reordenação de pacotes com 500.000 passos

Esses resultados mostram que as condições da rede demandam mais treinamento dos sistemas e algumas métricas de QoS afetam mais o comportamento do agente do que outras. Ao comparar a taxa de reordenação de pacotes e jitter, podemos ver que a taxa de envio imediata dita o

comportamento das curvas. À medida que aumentamos a taxa, pudemos ver que o comportamento do agente tende a se estabilizar.

A conclusão geral deste cenário é que algumas métricas de QoS interferem mais no controle remoto de uma aplicação do que outras. Por exemplo, a taxa de perda de pacotes fez com que o comportamento do agente se tornasse inconsistente ao levar mais tempo para concluir o episódio mais rapidamente do que ao modificar a taxa de corrupção de pacotes.

4.2 Agente treinado na rede

Após analisar os resultados baseados em aplicativos ao usar um agente pré-treinado com 500.000 passos, o cenário de teste pode ser estendido. Foi possível observar o comportamento do agente levando em consideração o processo de treinamento. Para isso, utilizamos um agente treinado online sob as modificações dos parâmetros de rede. O objetivo é ver como o agente se comporta quando seu treinamento é suscetível à qualidade da rede, como atrasos e perdas de pacotes. Pudemos ver que as condições da rede demandam mais treinamento dos agentes, pois é necessário um treinamento mais robusto em uma rede com menor qualidade. Assim, o desempenho do agente treinado offline no mesmo ambiente do OpenAI Gym com 20.000 passos foi comparado com o desempenho de um agente treinado online. Foi possível observar que treinar o agente sob má qualidade de rede tornou seu desempenho pior e mais imprevisível do que quando se utiliza um agente treinado sob boas qualidades de rede.

Latência: A Figura 4.11 exibe a comparação entre o agente pré-treinado (offline) e o agente treinado em condições de rede (online) ao variar a latência sob as métricas necessárias para um sistema de rede elétrica industrial (NASRALLAH et al., 2018). Pode-se observar que o primeiro agente teve um desempenho relativamente melhor que o segundo, pois a qualidade da rede não influenciou seu treinamento. Apesar de ambos terem sido treinados no mesmo algoritmo e com o mesmo número de passos de treinamento, o agente com treinamento offline tem uma curva de tempo menos díspar, enquanto o agente treinado online foi suscetível à deterioração do desempenho. A Figura 4.12 mostra o aumento do número de ações realizadas em um episódio e a diminuição de sua recompensa média.

Perda de pacotes: Ao considerar a taxa de perda de pacotes de uma rede real, foi possível avaliar o comportamento do agente treinado online. Para comparar o agente treinado online com o agente pré-treinado, a Figura 4.13 expõe como o tempo médio para o braço robótico atingir o alvo aumenta consideravelmente à medida que a qualidade da rede se deteriora a taxas mais altas para o agente com treinamento online. A recompensa média obtida pelo agente com nenhum pré-treino cai quando a taxa de perda de pacotes excede 0,5%, e as recompensas são sempre piores que a recompensa média obtida pelo agente com pré-treino (Fig. 4.14).

Pode-se observar que a latência da rede fez com que o agente implantado com treinamento zero fizesse com que a recompensa caísse para níveis consideravelmente mais baixos nas primeiras

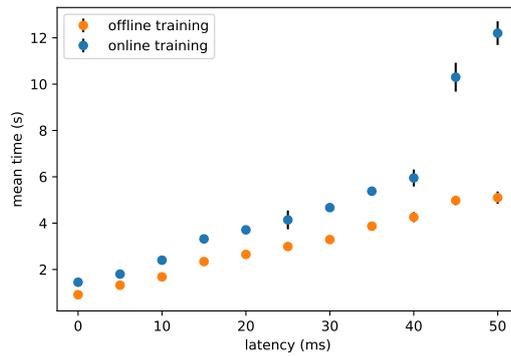


Figura 4.11 – Tempo médio de conclusão da tarefa variando a latência da rede com 20.000 passos

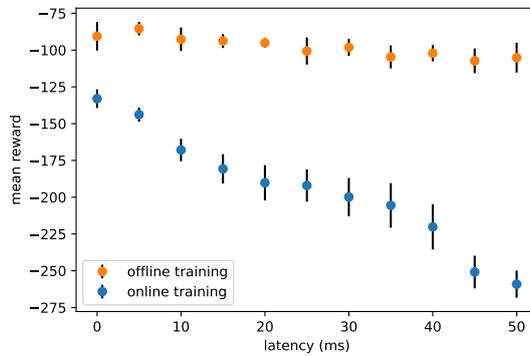


Figura 4.12 – Recompensa média variando a latência da rede com 20.000 passos

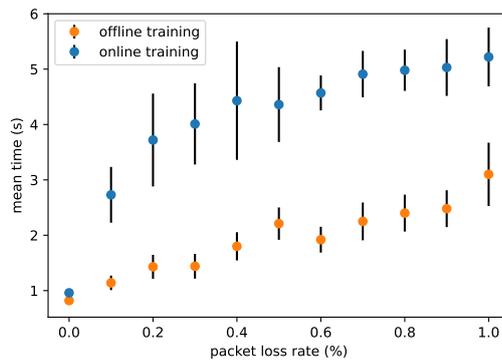


Figura 4.13 – Tempo médio de conclusão da tarefa para perda de pacotes variável na rede com 20.000 passos

variações de latência do que com os primeiros aumentos na taxa de perda de pacotes. Ao comparar as duas métricas lado a lado, percebe-se que o tempo para concluir um episódio é maior à medida que a latência aumenta. Acima de tudo, a recompensa média obtida no final do episódio quando a taxa se aproxima de 1% de perda de pacotes cai substancialmente.

Corrupção de pacotes: Por fim, ao levar em consideração a taxa de corrupção de pacotes, é possível analisar uma notória falta de controle no comportamento do braço robótico

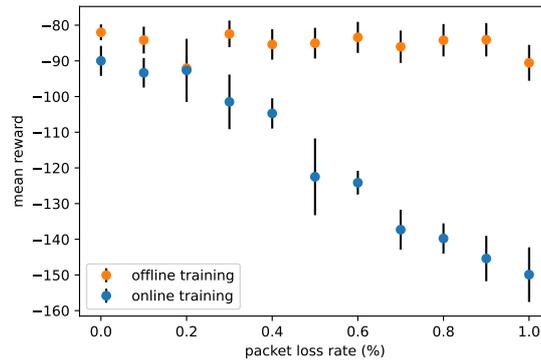


Figura 4.14 – Recompensa média variando a perda de pacotes de rede com 20.000 passos

nos episódios em que a taxa de corrupção se aproximou de 1%. Nessas situações, o fato de o agente treinado online aprender a realizar suas ações em uma rede na qual os pacotes relacionados ao seu treinamento foram corrompidos, fez com que ele demorasse mais para atingir seu objetivo. A Figura 4.15 apresenta o tempo médio para completar o episódio, que se aproxima de 3 segundos. Assim, podemos ver como as recompensas de um agente treinado online são sempre menores do que a recompensa média obtida com o agente treinado offline. Observe também que as recompensas obtidas do agente pré-treinado permanecem mesmo com mudanças na qualidade da rede. Como utilizamos um agente pré-treinado em condições ideais de rede, é natural que seu treinamento mantenha o desempenho do mesmo agente, como podemos ver na Figura 4.16.

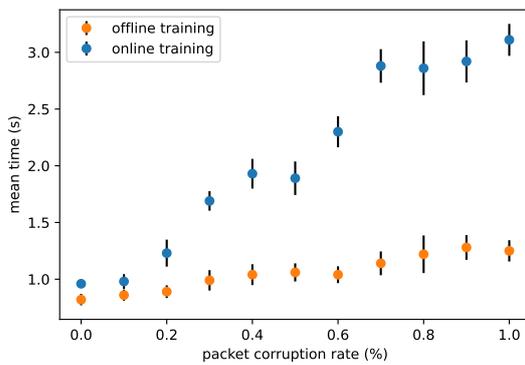


Figura 4.15 – Variação do tempo médio

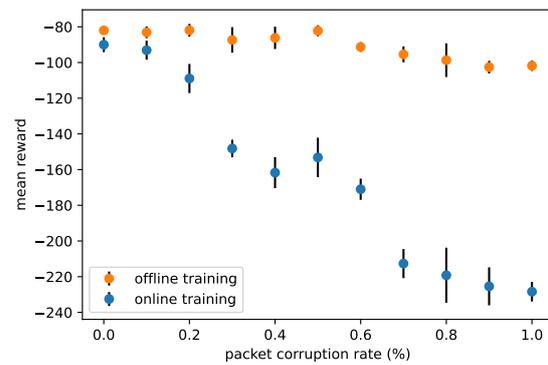


Figura 4.16 – Variação da recompensa média

Os resultados acima indicam que é melhor usar um agente pré-treinado em condições ideais de rede do que implantar um agente sem nenhum treinamento em uma rede instável.

5 Considerações Finais

O presente trabalho permitiu avaliar os resultados dos efeitos de características de QoS de uma rede real no desempenho de aplicações simuladas para controle remoto na Indústria 4.0. Ao controlar remotamente um dispositivo industrial, o operador é capaz de manter uma interação bidirecional e em tempo real. Com foco na interação com os processos industriais, alguns exemplos foram apresentados para mostrar os recursos existentes que já são aplicados na indústria. Com a integração de ferramentas de simulação de redes e de processos físicos, foi desenvolvido um simulador que consegue metrificar o impacto de variações da QoS de uma rede no desempenho da execução de ações realizadas por um agente em um ambiente simulado. Além disso, foi possível avaliar os resultados não somente levando em conta a aplicação, mas o próprio aprendizado por reforço do agente.

Para trabalhos futuros, deve-se levar em conta o uso do simulador para detectar quando uma rede passa por perdas e atrasos e treinar dinamicamente o agente para aumentar sua recompensa obtida. A noção de aprendizado por reforço pode ser ampliada ao utilizar outras métricas de QoS para avaliação em conjunto com a realização de testes para mais cenários. Será necessário abordar no futuro o desenvolvimento e validação de um ecossistema IoT de controle remoto para a Indústria 4.0 em uma linha de produção real. Considerar a opinião de operadores no chão de fábrica também é válido, visto que as aplicações de controle remoto servem como facilitadores para seu cotidiano no trabalho. A tecnologia 5G será capaz de melhorar significativamente a transmissão de dados entre aplicações e fará com que haja a integração de cada vez mais dispositivos IoT no cenário industrial.

5.1 Conclusão

O objetivo desse trabalho era desenvolver um simulador capaz de avaliar o impacto que métricas de QoS desempenham sobre um agente treinado em RL. Demonstramos que conforme a qualidade da rede piora, o desempenho geral do agente é impactado negativamente. Além disso, foi possível observar que algumas métricas de QoS interferem mais no controle remoto de uma aplicação do que outras. Outro fator constatado pelo estudo diz respeito ao processo de aprendizagem por reforço de um agente. Foi observado que as condições de rede demandam maior treinamento dos agentes. Logo, para uma aplicação real, é melhor que o agente se adapte dinamicamente às perdas e atrasos de uma rede real e seja treinado continuamente. Visto que a Indústria 4.0 está em constante evolução, há a necessidade da difusão de redes de computadores de alta qualidade para ajudar os produtores a integrar dispositivos IoT capazes de atender à crescente demanda dos clientes e manter a indústria competitiva no mercado global.

Referências

- ACCORSI, R.; BORTOLINI, M.; BARUFFALDI, G.; PILATI, F.; FERRARI, E. Internet-of-things paradigm in food supply chains control and management. *Procedia Manufacturing*, v. 11, p. 889–895, 2017. ISSN 2351-9789. 27th International Conference on Flexible Automation and Intelligent Manufacturing, FAIM2017, 27-30 June 2017, Modena, Italy. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2351978917304006>>.
- AKPAKWU, G. A.; SILVA, B. J.; HANCKE, G. P.; ABU-MAHFOUZ, A. M. A survey on 5g networks for the internet of things: Communication technologies and challenges. *IEEE access*, IEEE, v. 6, p. 3619–3647, 2017.
- AL-TURJMAN, F.; LEMAYIAN, J. P.; ALTURJMAN, S.; MOSTARDA, L. Enhanced deployment strategy for the 5g drone-bs using artificial intelligence. *IEEE Access*, IEEE, v. 7, p. 75999–76008, 2019.
- AMARAL, B. do. 5g terá pico de 10 gbps e latência de 1 ms, define uit. In: . [s.n.], 2015. Disponível em: <<https://www.mobiletime.com.br/noticias/30/10/2015/5g-tera-pico-de-10-gbps-e-latencia-de-1-ms-define-uit/>>.
- ARDANZA, A.; MORENO, A.; SEGURA Álvaro; CRUZ, M. de la; AGUINAGA, D. Sustainable and flexible industrial human machine interfaces to support adaptable applications in the industry 4.0 paradigm. *International Journal of Production Research*, Taylor Francis, v. 57, n. 12, p. 4045–4059, 2019. Disponível em: <<https://doi.org/10.1080/00207543.2019.1572932>>.
- ARRIETA, A.; SAGARDUI, G.; ETXEBERRIA, L. A model-based testing methodology for the systematic validation of highly configurable cyber-physical systems. In: IARIA XPS PRESS. *The Sixth International Conference on Advances in System Testing and Validation Lifecycle*. [S.l.], 2014. p. 66–72.
- ATZORI, L.; IERA, A.; MORABITO, G. The internet of things: A survey. *Computer Networks*, v. 54, n. 15, p. 2787–2805, 2010. ISSN 1389-1286. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1389128610001568>>.
- BELTRÃO, S. R. B. B.; PIRES, A. A. de O. Generation of corporate intelligence in industry 4.0, through the combination of professional drones and artificial intelligence. case study applied to a coal recovery boiler. *Brazilian Journal of Technology*, v. 2, n. 4, p. 946–966, 2019.
- BUCHNER, R.; WURHOFER, D.; WEISS, A.; TSCHELIGI, M. User experience of industrial robots over time. In: *2012 7th ACM/IEEE International Conference on Human-Robot Interaction (HRI)*. [S.l.: s.n.], 2012. p. 115–116.
- CARMEN, G. D. Tudo que você precisa saber sobre o 5g. In: . [s.n.], 2021. Disponível em: <<https://forbes.com.br/forbes-tech/2021/04/tudo-que-voce-precisa-saber-sobre-o-5g/>>.
- CHEN, Y.; FARLEY, T.; YE, N. Qos requirements of network applications on the internet. *Information Knowledge Systems Management*, IOS Press, v. 4, n. 1, p. 55–76, 2004.
- CHENG, J.; CHEN, W.; TAO, F.; LIN, C.-L. Industrial iot in 5g environment towards smart manufacturing. *Journal of Industrial Information Integration*, v. 10, p. 10–19, 2018.

ISSN 2452-414X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2452414X18300049>>.

CIVERCHIA, F.; GIANNONE, F.; KONDEPU, K.; CASTOLDI, P.; VALCARENGHI, L.; BRAGAGNINI, A.; GATTI, F.; NAPOLITANO, A.; BORROMEO, J. C. Remote control of a robot rover combining 5g, ai, and gpu image processing at the edge. In: OPTICAL SOCIETY OF AMERICA. *Optical Fiber Communication Conference*. [S.l.], 2020. p. M3Z–10.

CONSULTING, V.-S. *How AI Enables Successful Remote Work Strategy*. 2020. <https://blog.vsoftconsulting.com/blog/how-ai-enables-successful-remote-work-strategy>. Accessed in 01.15.2022.

ETSI. Service requirements for cyber-physical control applications in vertical domains. 9 2020. Accessed in 01.10.2022. Disponível em: <https://www.etsi.org/deliver/etsi_ts/122100_122199/122104/16.05.00_60/ts_122104v160500p.pdf/>.

HARRIS, C. J. *Advances in intelligent control*. [S.l.]: CRC Press, 1994.

HUANG, G.; RAO, P. S.; WU, M.-H.; QIAN, X.; NOF, S. Y.; RAMANI, K.; QUINN, A. J. Vipo: Spatial-visual programming with functions for robot-iot workflows. In: *Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems*. [S.l.: s.n.], 2020. p. 1–13.

IERA, A.; FLOERKEMEIER, C.; MITSUGI, J.; MORABITO, G. The internet of things [guest editorial]. *IEEE Wireless Communications*, v. 17, n. 6, p. 8–9, 2010.

JOVANE, F.; YOSHIKAWA, H.; ALTING, L.; BOËR, C.; WESTKAMPER, E.; WILLIAMS, D.; TSENG, M.; SELIGER, G.; PACI, A. The incoming global technological and industrial revolution towards competitive sustainable manufacturing. *CIRP Annals*, v. 57, n. 2, p. 641–659, 2008. ISSN 0007-8506. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0007850608001959>>.

KALØR, A. E.; GUILLAUME, R.; NIELSEN, J. J.; MUELLER, A.; POPOVSKI, P. Network slicing for ultra-reliable low latency communication in industry 4.0 scenarios. *arXiv preprint arXiv:1708.09132*, 2017.

KARRE, H.; HAMMER, M.; KLEINDIENST, M.; RAMSAUER, C. Transition towards an industry 4.0 state of the leanlab at graz university of technology. *Procedia Manufacturing*, v. 9, p. 206–213, 2017. ISSN 2351-9789. 7th Conference on Learning Factories, CLF 2017. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2351978917301245>>.

KIM JUNSUNG E KIM, H. e. L. K. e. R. R. R. Programação paralela para sistemas cibernéticos-físicos: Análise e estudo de caso em um carro autônomo. *Association for Computing Machinery*, 2013.

KUNST, R.; AVILA, L.; BINOTTO, A.; PIGNATON, E.; BAMPI, S.; ROCHOL, J. Improving devices communication in industry 4.0 wireless networks. *Engineering Applications of Artificial Intelligence*, Elsevier, v. 83, p. 1–12, 2019.

LI, Z.; UUSITALO, M. A.; SHARIATMADARI, H.; SINGH, B. 5g urllc: Design challenges and system concepts. In: IEEE. *2018 15th International Symposium on Wireless Communication Systems (ISWCS)*. [S.l.], 2018. p. 1–6.

- LIBERATO, A.; MARTINELLO, M.; GOMES, R. L.; BELDACHI, A. F.; SALAS, E.; VILLACA, R.; RIBEIRO, M. R.; KONDEPU, K.; KANELLOS, G.; NEJABATI, R. et al. Rdna: Residue-defined networking architecture enabling ultra-reliable low-latency datacenters. *IEEE Transactions on Network and Service Management*, IEEE, v. 15, n. 4, p. 1473–1487, 2018.
- LOBBRECHT, A. H.; SOLOMATINE, D. P. Machine learning in real-time control of water systems. *Urban Water*, Elsevier, v. 4, n. 3, p. 283–289, 2002.
- LU, C.; SAIFULLAH, A.; LI, B.; SHA, M.; GONZALEZ, H.; GUNATILAKA, D.; WU, C.; NIE, L.; CHEN, Y. Real-time wireless sensor-actuator networks for industrial cyber-physical systems. *Proceedings of the IEEE*, v. 104, n. 5, p. 1013–1024, 2016.
- MAGALHAES, A. L. Quais são as diferenças entre redes 1g, 2g, 3g, 4g, 5g e 6g? In: . [s.n.], 2021. Disponível em: <<https://canaltech.com.br/internet/diferencas-entre-1g-2g-3g-4g-5g-6g/>>.
- MANAVALAN, E.; JAYAKRISHNA, K. A review of internet of things (iot) embedded sustainable supply chain for industry 4.0 requirements. *Computers & Industrial Engineering*, Elsevier, v. 127, p. 925–953, 2019.
- MARQUES, P.; CARMO, A. P. do; FRASCOLLA, V.; SILVA, C.; SENA, E. D.; BRAGA, R.; PINHEIRO, J.; ASTUDILLO, C. A.; ANDRADE, T. P. de; GAMA, E. S. et al. Optical and wireless network convergence in 5g systems—an experimental approach. In: IEEE. *2018 IEEE 23rd International Workshop on Computer Aided Modeling and Design of Communication Links and Networks (CAMAD)*. [S.l.], 2018. p. 1–5.
- MCLEOD, S. *What are Confidence Intervals in Statistics?* 2019. <https://www.simplypsychology.org/confidence-interval.html>. Accessed in 06.02.2022.
- NAKIMULI, W.; GARCIA-REINOSO, J.; SIERRA-GARCIA, J. E.; SERRANO, P.; FERNÁNDEZ, I. Q. Deployment and evaluation of an industry 4.0 use case over 5g. *IEEE Communications Magazine*, IEEE, v. 59, n. 7, p. 14–20, 2021.
- NASRALLAH, A.; THYAGATURU, A. S.; ALHARBI, Z.; WANG, C.; SHAO, X.; REISSLEIN, M.; ELBAKOURY, H. Ultra-low latency (ull) networks: The ieee tsn and ietf detnet standards and related 5g ull research. *IEEE Communications Surveys & Tutorials*, IEEE, v. 21, n. 1, p. 88–145, 2018.
- NIELSEN, J. J.; LIU, R.; POPOVSKI, P. Ultra-reliable low latency communication using interface diversity. *IEEE Transactions on Communications*, v. 66, n. 3, p. 1322–1334, 2018.
- PAPCUN, P.; KAJÁTI, E.; KOZIOREK, J. Human machine interface in concept of industry 4.0. In: *2018 World Symposium on Digital Intelligence for Systems and Machines (DISA)*. [S.l.: s.n.], 2018. p. 289–296.
- PAPCUN, P.; ČOPÍK, M. Remote control of mitsubishi industrial robot. In: . [S.l.: s.n.], 2012.
- POPOVSKI, P.; STEFANOVIĆ, Č.; NIELSEN, J. J.; CARVALHO, E. D.; ANGJELICHINOSKI, M.; TRILLINGSGAARD, K. F.; BANA, A.-S. Wireless access in ultra-reliable low-latency communication (urllc). *IEEE Transactions on Communications*, IEEE, v. 67, n. 8, p. 5783–5801, 2019.

- QIU, X.; LUO, H.; XU, G.; ZHONG, R.; HUANG, G. Q. Physical assets and service sharing for iot-enabled supply hub in industrial park (ship). *International Journal of Production Economics*, v. 159, p. 4–15, 2015. ISSN 0925-5273. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0925527314002795>>.
- RAFFIN, A.; HILL, A.; GLEAVE, A.; KANERVISTO, A.; ERNESTUS, M.; DORMANN, N. Stable-baselines3: Reliable reinforcement learning implementations. *Journal of Machine Learning Research*, v. 22, n. 268, p. 1–8, 2021. Disponível em: <<http://jmlr.org/papers/v22/20-1364.html>>.
- ROBLA, S.; BECERRA, V.; LLATA, J.; GONZALEZ-SARABIA, E.; TORRE-FERRERO, C.; PÉREZ-ORIA, J. Working together: A review on safe human-robot collaboration in industrial environments. *IEEE Access*, PP, p. 1–1, 11 2017.
- RODRIGUEZ, I.; MOGENSEN, R. S.; FINK, A.; RAUNHOLT, T.; MARKUSSEN, S.; CHRISTENSEN, P. H.; BERARDINELLI, G.; MOGENSEN, P.; SCHOU, C.; MADSEN, O. An experimental framework for 5g wireless system integration into industry 4.0 applications. *Energies*, Multidisciplinary Digital Publishing Institute, v. 14, n. 15, p. 4444, 2021.
- SANTOS, B. P.; ALBERTO, A.; LIMA, T. D. F. M.; CHARRUA-SANTOS, F. M. B. Indústria 4.0: desafios e oportunidades. *Revista Produção e Desenvolvimento*, v. 4, n. 1, p. 111–124, 2018.
- SIMONINI, T. *An intro to Advantage Actor Critic methods: let's play Sonic the Hedgehog!* 2018. <https://www.freecodecamp.org/news/an-intro-to-advantage-actor-critic-methods-lets-play-sonic-the-hedgehog-86d6240171d/>. Accessed in 06.02.2022.
- VYSOCKY, A.; NOVAK, P. Human-robot collaboration in industry. *MM Science Journal*, v. 9, n. 2, p. 903–906, 2016.
- YANG, S.-Y.; JIN, S.-M.; KWON, S.-K. Remote control system of industrial field robot. In: IEEE. *2008 6th IEEE International Conference on Industrial Informatics*. [S.l.], 2008. p. 442–447.
- YANG WU, D. L. L. e. a. Supply chain dea: Production possibility set and performance evolution model. *Annals of Operations Research*, v. 185, p. 195–211, 2011.
- YU, H.; LEE, H.; JEON, H. What is 5g? emerging 5g mobile services and network requirements. *Sustainability*, Multidisciplinary Digital Publishing Institute, v. 9, n. 10, p. 1848, 2017.