CENTRO UNIVERSITÁRIO FEI

RODRIGO DE CARVALHO TECHI

GERENCIAMENTO DINÂMICO DE ENERGIA APLICADO A UM ROBÔ MÓVEL

São Bernardo do Campo

2021

RODRIGO DE CARVALHO TECHI

GERENCIAMENTO DINÂMICO DE ENERGIA APLICADO A UM ROBÔ MÓVEL

Dissertação de Mestrado, apresentada ao Centro Universitário da FEI para obtenção do título de Mestre em Engenharia Elétrica. Orientado pelo Prof. Dr. Plinio Thomaz Aquino Junior.

São Bernardo do Campo

2021

centro universitário FEI

APRESENTAÇÃO DE DISSERTAÇÃO
ATA DA BANCA EXAMINADORA

Programa de Pós-Graduação Stricto Sensu em Engenharia Elétrica

Mestrado

PGE-10

Aluno: Rodrigo de Carvalho Techi **Matrícula:** 118323-5

Título do Trabalho: Gerenciamento dinâmico de energia aplicado a um robô móvel.

Área de Concentração: Inteligência Artificial Aplicada à Automação e Robótica

Orientador: Prof. Dr. Plínio Thomaz Aquino Junior

Data da realização da defesa: 27/10/2021

ORIGINAL ASSINADA

Avaliação da Banca Examinadora:

A banca foi realizada no dia 27 de Outubro às 09:30 horas, com uma boa apresentação realizada pelo aluno. A arguição ocorreu debatendo-se aspectos teóricos e metodológicos, onde o aluno respondeu todas as questões de forma adequada demonstrando conhecimento pleno do tema. Comentários foram realizados para melhoria do texto em sua versão final, e foram incluidos nas atas individuais dos membros da banca. A aprovação ocorreu por unanimidade.

São Bernardo do Campo, / / .

MEMBROS DA BANCA EXAMINADORA	
Prof. Dr. Plínio Thomaz Aquino Junior	Ass.: _____
Prof. Dr. Fabio Delatore	Ass.: _____
Prof. Dr. Luiz Antonio Celiberto Junior	Ass.: _____

A Banca Julgadora acima-assinada atribuiu ao aluno o seguinte resultado:

APROVADO ☒ REPROVADO ☐

VERSÃO FINAL DA DISSERTAÇÃO

APROVO A VERSÃO FINAL DA DISSERTAÇÃO EM QUE FORAM INCLUÍDAS AS RECOMENDAÇÕES DA BANCA EXAMINADORA

_____

Aprovação do Coordenador do Programa de Pós-graduação

_____

Prof. Dr. Carlos Eduardo Thomaz

Carvalho Techi, Rodrigo de .
Gerenciamento dinâmico de energia aplicado a um robô móvel / Rodrigo de Carvalho Techi. São Paulo, 2021.
67 f. : il.

Dissertação - Centro Universitário FEI.
Orientador: Prof. Dr. Plinio Thomaz Aquino Junior.

1. Gerenciamento Dinâmico de Energia. 2. Auxilio em decisões voltadas ao consumo de energia. 3. Robô Móvel. I. Thomaz Aquino Junior, Plinio, orient. II. Título.

Elaborada pelo sistema de geração automática de ficha catalográfica da FEI com os dados fornecidos pelo(a) autor(a).

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001

RESUMO

A lei de Moore previu, a cada dois anos, 100% de aumento no número de transistores em um circuito impresso, mantendo o mesmo custo. Baterias têm sua capacidade determinada pela densidade energética (Watt-h/kg), e para que o valor dobrasse foi necessária uma década. Tendo em vista a discrepância entre as taxas de evolução, os equipamentos cada vez consomem mais energia, sem que a fonte consiga armazena-la com o mesmo volume. Tais fatos provocam problemas para sistemas energizados por baterias como, por exemplo, carros elétricos, robôs móveis, casas inteligentes, *laptops*, *smartphones*, entre outros. A área da robótica móvel é a mais afetada pois, diferente de carros elétricos, que podem ter grandes bancos de baterias ou de aparelhos eletrônicos que podem ser facilmente utilizados enquanto são recarregados, os sistemas robóticos moveis não possuem espaço suficiente para uma grande quantidade de baterias e sua recarga requer um intervalo de tempo no qual o robô ficara inoperante. Adicionando o fato de um robô móvel ter uma variedade de sensores e atuadores para realizar uma diversa gama de tarefas, o consumo eficiente de energia se torna uma necessidade para proporcionar uma boa experiência para o usuário. O Gerenciamento Dinâmico de Energia (DPM, *Dynamic Power Management*) propõe o uso otimizado de energia através do controle de gasto energético de equipamentos presentes em um sistema, o que é feito através da exploração da ociosidade: Sempre que um aparelho (ou um componente de um aparelho) estiver ocioso, sua dissipação de energia deve ser reduzida o máximo possível. Este trabalho propõe a modelagem de um sistema de Gerenciamento Dinâmico de Energia em robôs móveis, com objetivo de aumentar o tempo de funcionamento, desenvolver um sistema de captação de dados para futuras tomadas de decisões relacionadas ao sistema de energia e a realização de tarefas, e criar uma base de conhecimento do funcionamento de sensores e atuadores em robôs móveis de plataforma aberta.

Palavras-chave: Gerenciamento Dinâmico de Energia. Robô Móvel. Auxilio em decisões voltadas ao consumo de energia.

ABSTRACT

Moore's law predicted a 100% increase in the number of transistors on a printed circuit every two years, while maintaining the same cost. Batteries have their capacity provided by energy density (Watt-h / kg), and for that value to double it took a decade. Considering the discrepancy between evolution rates, the equipment consumes more and more energy, without the energy source being able to store it with the same volume. Such facts cause problems for systems powered by batteries, such as electric cars, mobile robots, smart houses,laptops, smartphones, among others. The area of service robotics is affected more severely by this, as unlike electric cars, which can have large battery banks, or electronic devices that can be easily used while being recharged, robotic service systems do not have enough space for a large number of batteries, and recharging requires a time interval in which the robot will be inoperable. Adding to the fact that a service robot has a variety of sensors and actuators to perform a diverse range of tasks, efficient energy consumption becomes a necessity to provide a good user experience. DPM proposes the optimized use of energy by controlling the energy expenditure of equipment present in a system, which is done through the exploration of idleness: Whenever a device (or a device component) is idle, its energy dissipation should be reduced as much as possible. This work proposes the modeling of a Dynamic Power Management system in mobile robots, in order to increase its runtime, teh development of a data acquisition system for future energy related decision-making, and the creation a knowledge base of the functioning of sensors and actuators in open platform mobile robots.

Keywords: Dynamic Energy Management. Mobile Robot. Assistance in decisions related to energy consumption.

LISTA DE ABREVIATURAS

DPM	Gerenciamento Dinâmico de Energia (*Dynamic Power Management*)
DVS	Escala Dinâmica de Tensão (*Dynamic Voltage Scaling*)
FPGA	Arranjo de Portas Programáveis em Campo (*Field Programmable Gate Array*)
HERA	Robô de Assistência para Ambientes Domésticos (*Home Environment Robot Assistant*)
ROS	Sistema Operacional Robótico (*Robot Operating System*)
SoC	Estado de Carga (*State of Charge*)
SoH	Estado de Saúde (*State of Health*)
WMR	Robôs Móveis com Rodas (*Wheeled Mobile Robots*)

LISTA DE ILUSTRAÇÕES

Figura 1 – 10 grande desafio na área da robótica científica 11
Figura 2 – Robô estacionário 15
Figura 3 – Robô quadrupede. 15
Figura 4 – Robôs de esteira 16
Figura 5 – Robô móvel sobre rodas 16
Figura 6 – Robô móvel híbrido 17
Figura 7 – Robôs aéreos 17
Figura 8 – Robô aquático 18
Figura 9 – Robôs móveis de serviço doméstico utilizados na RoboCup 19
Figura 10 – Componentes dos robôs participantes da RoboCup 20
Figura 11 – Sensores utilizados na navegação 22
Figura 12 – Utilização de atuadores em tarefas distintas 23
Gráfico 1 – Transição de estados de consumo 24
Figura 13 – Política de *Timeout* 25
Figura 14 – Política preditiva 27
Figura 15 – Representação genérica de aprendizado por reforço 30
Figura 16 – *Framework* para DPM. 31
Figura 17 – Robô de navegação marítima utilizado em Sauzé e Neal (2013). 35
Figura 18 – Rede neural utilizada para controle. 36
Figura 19 – Perfis previamente definidos e os respectivos estados dos periféricos. . . . 37
Figura 20 – Resultados dos métodos de economia de energia. 38
Figura 21 – Diagrama metodológico 39
Figura 22 – Robô HERA 41
Figura 23 – Componentes do robô HERA 41
Figura 24 – Resultado do mapeamento do robô HERA 43
Figura 25 – Baterias utilizadas pela equipe RoboFEI@Home 44
Figura 26 – Baterias e seus respectivos Estado de Saúde (SoH, *State of Health*) 44
Figura 27 – Fluxograma da tarefa sendo realizada 45
Figura 28 – Sistema de captação de dados 45
Figura 29 – Maquina de estados simulada neste trabalho. 46
Figura 30 – Módulos analisados e seus tempo de transição 46

Figura 31 – Módulos analisados e a tensão de suas respectivas fontes de energia. 47
Gráfico 2 – Consumo de cada módulo e consumo total. 48
Gráfico 3 – Consumo ideal de cada módulo e consumo ideal total. 48
Gráfico 4 – Consumo de cada módulo e consumo total com DPM *timeout* aplicado. . . 50
Gráfico 5 – Consumo de cada módulo e consumo total com DPM preditivo aplicado. . 51
Gráfico 6 – Consumo de cada módulo e consumo total com DPM preditivo e reinicio prévio aplicado. 52
Figura 32 – Tabela com métricas de análise 53
Gráfico 7 – Redução do C_T 54

SUMÁRIO

1 INTRODUÇÃO 10
1.1 OBJETIVO 12
1.2 JUSTIFICATIVA 12
1.3 MOTIVAÇÃO 13
2 REFERENCIAL TEÓRICO 14
2.1 ROBÔS MÓVEIS 14
2.2 GERENCIAMENTO DINÂMICO DE ENERGIA 20
2.2.1 Tipos de Ociosidade 21
2.2.2 Métodos de DPM 23
2.2.3 Implementação 30
3 TRABALHOS RELACIONADOS 32
4 METODOLOGIA 39
4.1 MÉTODOS 39
4.2 ROBÔ HERA 40
4.3 ANÁLISE DO SISTEMA 42
4.4 ROTEIRO DA TAREFA E MÉTODO DE ANÁLISE 43
4.5 SIMULAÇÃO 46
5 RESULTADO 47
5.1 POLÍTICA DE *TIMEOUT* 49
5.2 POLÍTICA PREDITIVA 50
5.3 DISCUSSÃO 53
6 CONCLUSÕES 55
APÊNDICE A – BASE DE CONHECIMENTO 57
REFERÊNCIAS 59

1 INTRODUÇÃO

Em Moore et al. (1965) foi dito que, a cada dois anos, o número de transistores em um circuito impresso dobraria sem que houvesse aumento no preço de produção. Tal declaração, apesar de não ser 100% valida nos dias atuais, serviu como um guia para a indústria no desenvolvimento de circuitos, possibilitando a execução das tarefas realizadas anteriormente em um menor espaço de tempo ou permitindo realizar mais tarefas em paralelo, sendo muito útil para o usuário que pode ter maior poder de processamento pelo mesmo preço. O desenvolvimento também fez com que a demanda energética de produtos eletrônicos aumentasse de forma proporcional à quantidade de componentes no circuito.

O aumento da necessidade de energia também está presente em aparelhos movidos à bateria, sendo que estes dispositivos não podem ser conectados à rede elétrica a fim de utilizá-la como fonte primária de energia. Nessa descrição se enquadram equipamentos nos quais a bateria fica alojada em seu interior e não pode ser removida para recarga como, por exemplo, celulares, carros totalmente elétricos, dentre outros. Também estão inclusos produtos que podem ter suas baterias removidas para recarga, porém não podem ser ligados à rede elétrica para uso. Nesta categoria estão inseridos drones, robôs móveis, carros e barcos operados via rádio controle, entre outros equipamentos.

Segundo Perrucci, Fitzek e Widmer (2011), diferentemente do que ocorre com o número de transistores em um circuito impresso denso, a evolução das baterias não seguiu a taxa descrita por Moore. Baterias podem ter sua capacidade determinada pela densidade energética (Watt-h/kg), e para que esse valor dobrasse foi necessária uma década.

No trabalho Yang et al. (2018) foram levantados os 10 grandes desafios na área da robótica científica que podem ter grandes avanços, pesquisas significativas e/ou impacto socioeconômico nos próximos 5 à 10 anos, como é mostrado na Figura 1. Dentre os 10 desafios, o terceiro citado é referente a questões estratégicas da área energética. O trabalho ainda acrescenta que para sistemas eletrônicos, especialmente robôs móveis, problemas relacionados à energia são um dos mais desafiadores (YANG et al., 2018).

Figura 1 – 10 grande desafio na área da robótica científica

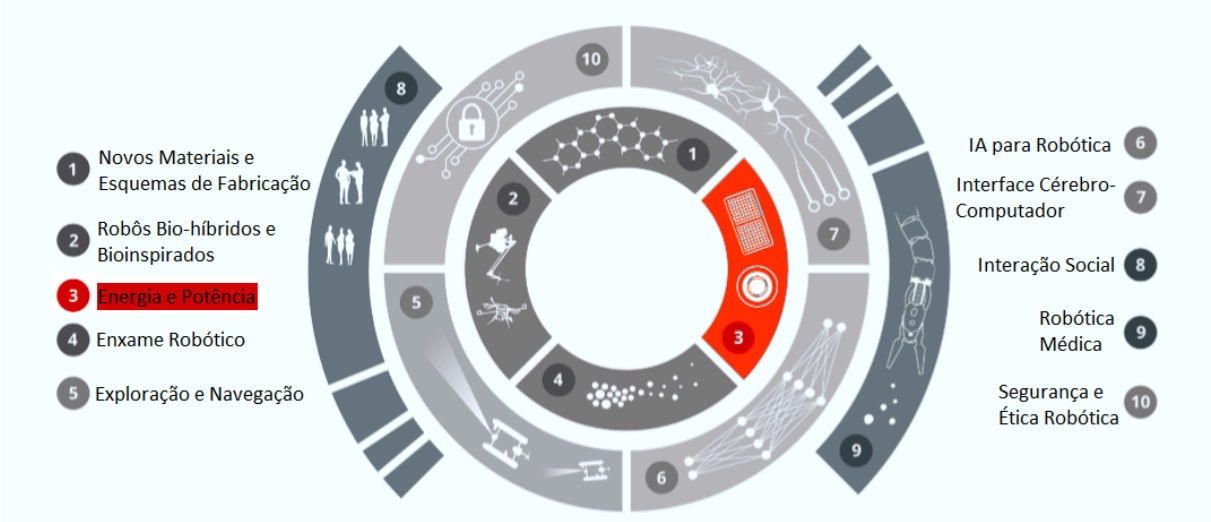

Fonte: o Autor "adaptado de"Guang-Zhong Yang et al. (2018)

Com os avanços tecnológicos nos últimos anos em conjunto às necessidades de controlar as emissões de agentes poluentes, sistemas movidos a bateria se encontram cada vez mais presentes. Se tornaram existentes em casas que geram e armazenam energia limpa, carros movidos a energia elétrica, aparelhos de uso pessoal como *smartphones* e acessórios eletrônicos, até mesmo robôs móveis.

Estes tipos de sistemas serão cada vez mais presentes, mas o problema com a matriz energética pode fazer com que os avanços sejam subutilizados pois o alto consumo de energia causa um tempo de serviço disponível extremamente baixo.

Para um robô móvel autônomo que tem baterias como a única fonte de energia, o maior limitante para o tempo de funcionamento é justamente a quantidade máxima de energia de suas baterias. A solução mais simples para aumentar a duração máxima seria a adição de mais células de carga, porém existem limites físicos, tanto de espaço quanto de peso máximo. Tais fatos fazem com que robôs móveis se beneficiem de um sistema que permita o aumento do tempo de execução.

Uma maneira de aumentar o tempo de funcionamento dos eletrônicos é a otimização do uso das baterias, gastando energia apenas com os equipamentos necessários para a execução das tarefas.

O DPM se alinha com a proposta de melhor utilização dos recursos disponíveis e propõe o uso otimizado de energia através do controle de gasto energético de equipamentos presentes em um sistema, o que é feito através da exploração da ociosidade: Sempre que um aparelho

(ou um componente de um aparelho) estiver ocioso, a dissipação de energia deve ser reduzida o máximo possível (BENINI; MICHELI, 1997).

O Robô de Assistência para Ambientes Domésticos (HERA, *Home Environment Robot Assistant*) é um robô móvel autônomo de assistência doméstica. Este robô realiza tarefas de casa de maneira autônoma, sem a necessidade de interferência humana. As tarefas vão desde reconhecer e organizar objetos em diferentes categorias até a recepção de pessoas em uma festa.

Para que consiga cumprir todas as tarefas, o robô dispõe de diversos módulos que não necessariamente operam ao mesmo tempo. Além disso, a fonte de energia do robô são baterias, fazendo com que ela se enquadre na categoria de equipamentos que se beneficiariam da aplicação de DPM.

1.1 OBJETIVO

Este trabalho propõe a concepção da estratégia de um sistema de Gerenciamento Dinâmico de Energia para ser aplicado em robôs móveis, com objetivo de aumentar o tempo de funcionamento, desenvolver um sistema de captação de dados para futuras tomadas de decisões relacionadas ao sistema de energia e a realização de tarefas, e criar uma base de conhecimento do funcionamento de sensores e atuadores em robôs móveis de plataforma aberta.

1.2 JUSTIFICATIVA

Os sistemas robóticos móveis estão cada vez mais generalistas, tendo que ser capazes de executar uma gama de funções, necessitando diversos sensores e atuadores. A alta mobilidade requerida por esses tipos de robôs faz com que baterias sejam a opção mais indicada de fonte energética.

A vasta gama de sensores utilizados por esse tipo de sistema robótico provoca um consumo energético elevado, tendo em vista que todos os sensores e atuadores estão sempre ativos, consumindo energia, mesmo quando não estão sendo utilizados. O elevado consumo sem o gerenciamento energético necessário se torna um obstáculo na experiência ao utilizar tais robôs, pois uma quantidade maior de paradas ocorreria, com a finalidade de troca ou recarga de baterias.

Após os estudos dos trabalhos em robótica móvel percebe-se que há a necessidade de gerar mais soluções para os problemas de energia, uma vez que a bateria é considerada um fator limitante para uso, mas ainda caminha para se tornar uma área a ser aprimorada.

Portanto, é necessária a adoção de métodos para um aumento na eficiência da utilização da energia disponível, pois um consumo mais eficiente gerará o benefício primário do aumento do tempo de serviço, diminuição na quantidade de ciclos de recarga, ocasionando aumento da vida útil das baterias e diminuirá a frequência de descarte e substituição de células de carga.

1.3 MOTIVAÇÃO

Após anos participando como membro da RoboFEI@Home e lidando com questões de elétrica e eletrônica da equipe, nota-se que um dos gargalos em momentos críticos em que o robô deveria funcionar por um grande período de tempo, era a disponibilidade de baterias devido ao alto consumo energético. Este fato gerou uma motivação para buscar maneiras de combater o gargalo e consequentemente, a elaboração desta pesquisa.

Nos próximos capítulos são apresentadas as principais áreas de pesquisa deste projeto, introduzindo os robôs móveis e os conceitos de gerenciamento dinâmico de energia. Em seguida são apresentados os trabalhos relacionados através de revisões sistemáticas. Na sequencia são apresentados os objetivos específicos do projeto, materiais e métodos utilizados. Finalmente são exibidos os resultados e a conclusão desta pesquisa.

2 REFERENCIAL TEÓRICO

Neste capítulo inicialmente é apresentada a robótica móvel e suas áreas, em conjunto com a definição do contexto de aplicação desta pesquisa. Em seguida é discutido o DPM, conceito chave do trabalho. São demonstrados os tipos de ociosidades e os métodos de gerenciamento dinâmico de energia existentes, além da definição da estrutura de implementação.

2.1 ROBÔS MÓVEIS

Segundo Ortigoza et al. (2012), robôs móveis podem ser definidos como sistemas elétricos e mecânicos capazes de se locomover de maneira autônoma de um ponto a outro, através de um ambiente de trabalho como, armazéns industriais, laboratórios, casas, hospitais, dentre outros. O nível de autonomia de um robô móvel pode ser determinado pelo seu domínio sobre o processo de deslocamento utilizando raciocínio próprio, com base em dados do ambiente fornecidos por sensores.

Rubio, Valero e Llopis-Albert (2019) trazem que, a partir do sistema de locomoção, um robô móvel se enquadra em alguma das categorias abaixo:

a) Estacionários (braço/manipulador)
b) Robôs Terrestres
   - Robô móvel com pernas
   - Robô móvel de deslizamento
   - Robô móvel sobre rodas
   - Híbridos
c) Robôs Aéreos
d) Robôs Aquáticos
e) Outros

Manipuladores e robôs industriais são exemplos de robôs estacionários. A base do robô é fixa e através das diferentes ferramentas que podem ser utilizadas como atuador, não apenas manipulam objetos, mas também podem realizar tarefas como soldagem, pintura, montagem, usinagem e assim por diante. Um exemplo de robô estacionário é exibido na Figura 2.

Figura 2 – Robô estacionário

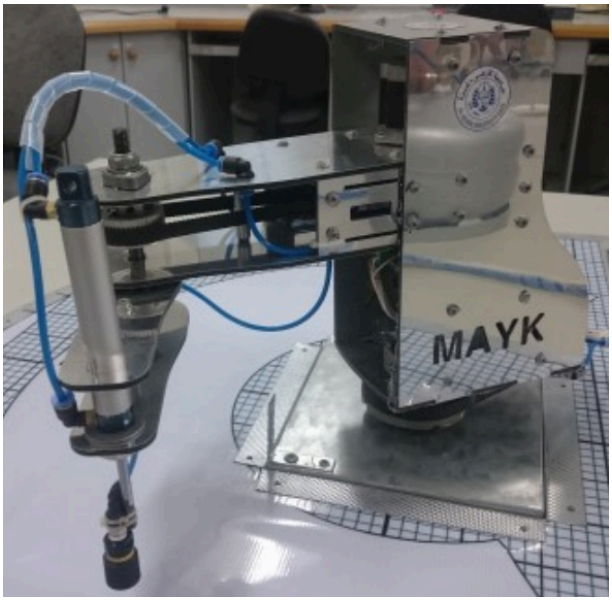

Fonte: o Autor "adaptado de"Ahmed Issa et al. (2017)

Para Silva e Machado (2012), os robôs com pernas, apesar de mais caros e complexos de se desenvolver, possuem a vantagem de serem adequados para uma variedade de terrenos, desde áreas com solo irregular, até escadas ou obstáculos presentes no dia a dia. Um exemplo deste tipo de robô é exibido na Figura 3, que traz a imagem do robô quadrupede *BigDog*.

Figura 3 – Robô quadrupede.

Fonte: o Autor "adaptado de"Marc Raibert et al. (2008)

O Robô móvel de deslizamento possui esteiras tracionadas como atuadores de locomoção. Com isso, esse tipo de robô possui uma área de contato maior com o chão, fornecendo

mais tração. Além disso, a utilização de esteiras proporciona uma maior mobilidade. Exemplos deste método de locomoção são exibidos na Figura 4, que mostra robôs de busca e resgate.

Figura 4 – Robôs de esteira

Fonte: o Autor "adaptado de"Bruno Siciliano e Oussama Khatib (2016)

Ainda segundo Rubio, Valero e Llopis-Albert (2019), rodas são uns dos mais importantes (e usuais) métodos de locomoção em robôs autônomos, formando a classe dos Robôs Móveis com Rodas (WMR, *Wheeled Mobile Robots*). Seu uso é mais simples do que a utilização de esteiras ou pernas, possui design, construção e programação mais simplificada. Além disso, rodas tendem a ser mais baratas e causar menos desgaste ao sistema. Um exemplo de WMR é exibido na Figura 5, que mostra um robô do campo da agricultura.

Figura 5 – Robô móvel sobre rodas

Fonte: o Autor "adaptado de"Tijmen Bakker et al. (2011)

Os robôs híbridos têm como ideia a união de métodos de locomoção com o objetivo de usufruir do melhor meio de acordo com o ambiente. Isso é mostrado em Sun et al. (2017), onde

é proposto um tipo de robô móvel transformável com pernas e rodas. O robô proposto é exibido na Figura 6.

Figura 6 – Robô móvel híbrido

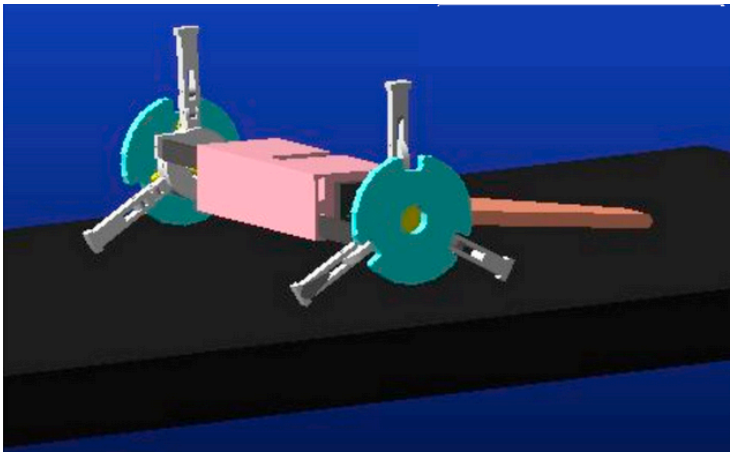

Fonte: o Autor "adaptado de"Bruno Siciliano e Oussama Khatib (2016)

Para Springer (2013), um veículo aéreo não tripulado, popularmente conhecido como *drone*, é uma máquina que realiza tarefas com ou sem a interação humana. Eles são capazes de decolar, navegar e aterrissar de maneira completamente autônoma. Suas áreas de atuação são extremamente amplas, desde segurança e vigilância, até a parte de filmagem, como exemplificado na Figura 7, que traz um robô aéreo de vigilância e um drone sendo usado para uma filmagem.

Figura 7 – Robôs aéreos

Fonte: o Autor "adaptado de"Leslie Pratt (2020) e C. Huang (2020)

Com o desejo de explorar ambientes submersos, robôs com capacidade de navegar embaixo d'água foram desenvolvidos. Um exemplo deste modelo é o *Ocean One*, mostrado na Figura 8: um robô humanoide submarino que explora o solo oceânico, apresentado em Khatib et al. (2016).

Figura 8 – Robô aquático

Fonte: o Autor "adaptado de"Oussama Khatib et al. (2016)

Além dos principais tipos de robôs citados, existem diversos grupos menores de robôs móveis como, por exemplo, robôs que se locomovem por rastejo (KAMAMICHI et al., 2006; BOXERBAUM; CHIEL; QUINN, 2009), robôs capazes de imitarem o movimento de peixes para se deslocar em ambientes aquáticos (SHINTAKE et al., 2020), micro e nano robôs (LUO et al., 2018), dentre outros.

Uma área da robótica móvel que vem se desenvolvendo é a parte da robótica de serviço. Os robôs de serviço são um amálgama de sistemas de software e hardware, com o objetivo de realizar tarefas diárias de assistência ao ser humano. Para as cumprir, os robôs devem ser capazes de navegar por um ambiente conhecido ou não. Além disso, a capacidade de detectar objetos e pessoas é essencial. Para permitir a interação é obrigatório reconhecer comandos de humanos (TECHI et al., 2020).

Dentre os impulsionadores desse desenvolvimento está a RoboCup@Home, uma competição de robótica composta por uma série de tarefas a serem resolvidas pelos robôs de serviço. O desempenho de cada um é avaliado com base em uma pontuação dada por juízes. O foco está nos seguintes domínios, mas não está limitado a: interação e cooperação humano-robô, navegação e mapeamento em ambientes dinâmicos, visão computacional e reconhecimento de objetos sob condições de luz natural, manipulação de objetos, comportamentos adaptativos, integração de comportamento, inteligência ambiental, padronização e integração do sistema (MATAMOROS et al., 2019).

Os robôs participantes da competição, apesar de terem cada um uma construção única, possuem características em comum como, a necessidade de alta mobilidade, todos são WMR, uma grande variedade de sensores e atuadores e baterias como fonte de energia, como pode ser visto nas Figuras 9 e 10. Eles apresentam, respectivamente, os robôs utilizados na competição RoboCup@Home e tabela com análise de sensores e atuadores de cada um destes robôs.

Figura 9 – Robôs móveis de serviço doméstico utilizados na RoboCup

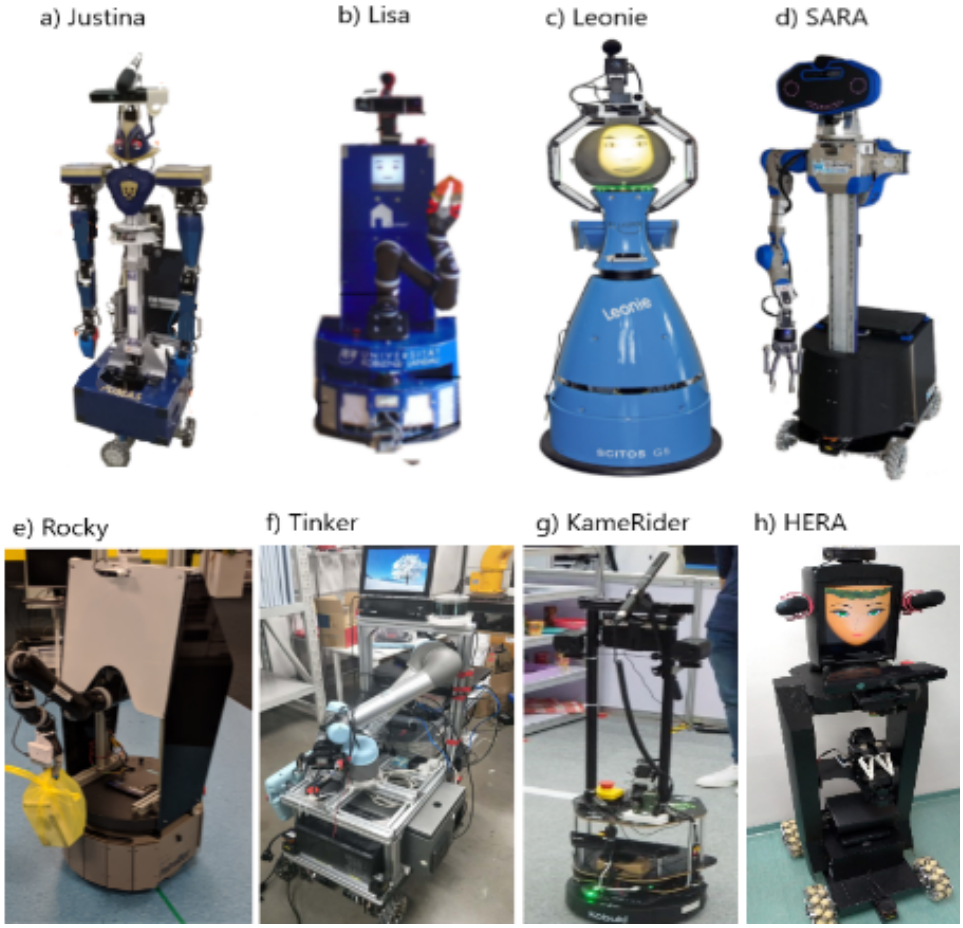

Fonte: (SAVAGE et al., 2019; MEMMESHEIMER et al., 2019; RATSCH et al., 2019; COUSINEAU; LE; AL, 2019; MARTIN et al., 2019; HUO et al., 2019; TAN, 2019; TECHI et al., 2020)

Figura 10 – Componentes dos robôs participantes da RoboCup

ROBO	EQUIPE	ATUADORES	SENSORES
JUSTINA	Pumas@Home	BASE | 2xMANIP | SPK | PTU | ELEV	MIC | LSR | KNT2 | CAM
LISA	homer@UniKoblenz	BASE | MANIP | SPK | PTU	MIC | LSR | KNT2 | LDR
Leonie	RT Lions	BASE | PTU | SPK	MIC | KNT2 | 2xCAM
SARA	WALINKG MACINE@Home	BASE | MANIP | SPK | PTU | ELEV	MIC | LSR | XT | MTR
ROCKY	ACRV@Home	BASE | MANIP | SPK	LSR | 2xRLS
TINKER	Tinker@Home	BASE | MANIP | SPK	MIC | 4xLSR | KNT | RLS | IMU
KAMEN	KameRider@Home	BASE | MANIP | SPK	MIC | KNT | XT | CAM
HERA	RoboFEI@Home	BASE | MANIP | SPK | PTU	MIC | LSR | KNT | XT | CAM | MTR

SPK= Caixa de som | MANIP=Manipulador | ELEV=Elevador | XT=Xtion | LSR=Laser | LDR=Lidar | MTR=Matriz de sensores
KNT=Kinect | RLS=RealSense | CAM=Camera | IMU= Unidade de Medição Inercial | PTU= Unidade de panorama e inclinação

Fontes: (SAVAGE et al., 2019; MEMMESHEIMER et al., 2019; RATSCH et al., 2019; COUSINEAU; LE; AL, 2019; MARTIN et al., 2019; HUO et al., 2019; TAN, 2019; TECHI et al., 2020)

Como os robôs são uma plataforma livre para desenvolvimento e pesquisa, os componentes utilizados vão sendo adicionados e substituídos com o decorrer do tempo, exigindo uma flexibilidade do sistema de alimentação.

Este trabalho se baseia em um robô móvel sobre rodas da área da robótica de serviço, porém possui potencial para ser aplicado nos mais diversos campos da robótica móvel devido ao modo como o sistema será tratado como um todo. Isto, junto aos métodos de gerenciamento de energia, será apresentado a seguir.

2.2 GERENCIAMENTO DINÂMICO DE ENERGIA

O DPM, segundo Benini, Bogliolo e De Micheli (1998) é uma metodologia de desenvolvimento que visa controlar o desempenho e o gasto energético de sistemas ou circuitos, com objetivo de estender o tempo de operação em aparelhos movidos a bateria tendo a menor redução de desempenho possível. Tem como conceito chave a exploração da ociosidade do sistema, desativando ou reduzindo o consumo de energia por partes do sistema que não estejam sendo utilizadas.

Sistemas robóticos móveis são desenvolvidos para realizar diversas tarefas diferentes, o que exige a utilização de diversos módulos, cada um com funções especificas às ações necessárias para o cumprimento da tarefa determinada pelo usuário. Porém, durante a maioria do funcionamento, não são utilizados todos os módulos disponíveis, o que torna partes do sistema ociosas (SAVAGE et al., 2019; MEMMESHEIMER et al., 2019; RATSCH et al., 2019; COU-

SINEAU; LE; AL, 2019; MARTIN et al., 2019; HUO et al., 2019; TAN, 2019; TECHI et al., 2020).

Para Benini, Bogliolo e De Micheli (2000), em um sistema de DPM ideal, primeiramente, a ociosidade é detectada com alta acurácia e, então, o recurso ocioso é rapidamente desativado e forçado para um estado em que a dissipação energética é a mínima possível. Sempre que o recurso sair do estado ocioso, a transição de desativado para ativo deve ser a mais rápida e eficiente possível, com foco em minimizar o tempo de espera do sistema até que o módulo esteja pronto para ser utilizado. A decisão de desativar o modulo é tomada durante a operação do sistema, de maneira dinâmica, o que implica em um gerenciador que deve sempre analisar interações entre o sistema e o ambiente externo para realizar a tomada de decisão.

De acordo com Dhiman e Rosing (2006), a implementação do DPM exige uma troca entre tempo mínimo de execução e gasto energético. Um sistema sem DPM tem todos os módulos sempre ativos, o que significa que estão sempre prontos para executarem suas ações no momento em que forem requisitados, porém o gasto energético é máximo. Com o DPM aplicado, os módulos são desativados durante o período ocioso, o que pode acarretar um atraso na execução da tarefa decorrente do tempo de reinicialização.

Para definir qual o método utilizado pelo gerenciador para enviar o módulo do sistema para um estado de baixo consumo, é necessário determinar se o módulo se torna ocioso pelos dados por ele adquiridos não serem levados em consideração para o funcionamento do sistema, ou se, com o passar do tempo, o módulo não é utilizado para a execução da tarefa.

A primeira ociosidade descrita é chamada de ociosidade externa, em oposição à interna, descrita logo em seguida. Elas serão analisadas separadamente nas seções seguintes.

2.2.1 Tipos de Ociosidade

Segundo Benini e Micheli (1997) ociosidade externa não é, isoladamente, uma propriedade de uma unidade computacional. Ela é induzida pelo ambiente através da necessidade de observação do estado do módulo analisado. Pode-se considerar uma ociosidade relacionada à observabilidade, pois no momento de analise a saída do módulo analisado não é utilizada para a realização da tarefa.

Um exemplo de gerenciamento de ociosidade externa é mostrada em Gary et al. (1994). O trabalho descreve um microprocessador de baixo consumo de energia. Caso o microprocessa-

dor esteja executando um código apenas de números inteiros, os ponteiros de números racionais (*float pointers*) são desabilitados.

Utilizando um robô móvel de serviço como exemplo, um módulo fica externamente ocioso caso a sua saída não seja levada em consideração para a execução da tarefa exigida pelo usuário.

A Figura 11 apresenta um exemplo de ociosidade externa. Durante a navegação, a saída do módulo Câmera não é observada pelo sistema para a execução da tarefa, sendo que o consumo energético continua o mesmo.

Figura 11 – Sensores utilizados na navegação

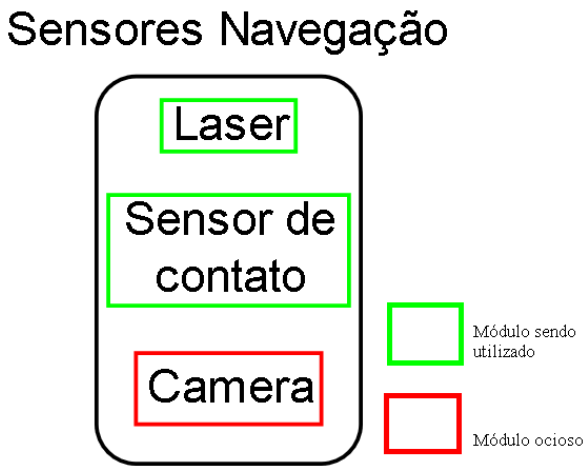

Fonte: Autor

Ainda segundo Benini e Micheli (1997), enquanto a ociosidade externa é causada por decisões fora do sistema, a interna depende exclusivamente do funcionamento do sistema com o passar do tempo.

A Figura 12 exibe um grupo de atuadores usualmente presentes em robôs móveis de serviço e seus status de uso em duas tarefas subsequentes. Observa-se que com o passar do tempo e consequente alteração da tarefa executada de Detecção para Manipulação, o modulo Base permanece ocioso. A ociosidade é causada pela lógica interna ao sistema, portanto, é denominada ociosidade interna.

Figura 12 – Utilização de atuadores em tarefas distintas

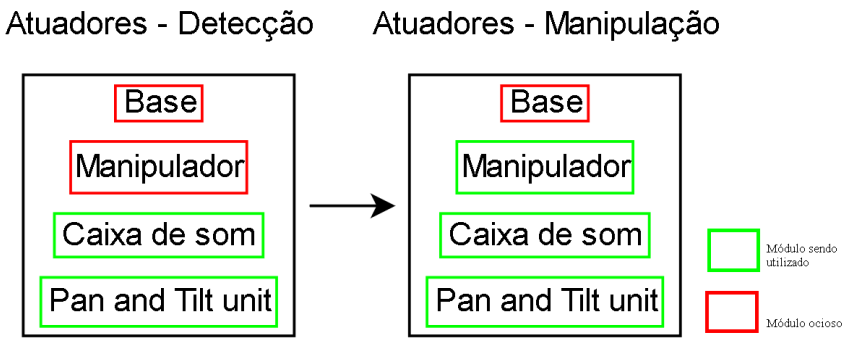

Fonte: Autor

No momento da detecção de objetos os atuadores Base e Manipulador não estão em uso. Supondo que a próxima ação seja a manipulação, o módulo Base se mantém inativo, porém continua consumindo energia desnecessariamente, o que conFigura uma ociosidade interna.

Após a definição de qual é o tipo de ociosidade em cada um dos módulos, é necessário definir um método para gerenciar o sistema. Este será o responsável por decidir quais e quando os módulos devem ou não ser enviados para um estado de baixo consumo.

2.2.2 Métodos de DPM

Para realizar as tomadas de decisões sobre quando desativar um equipamento, um método de gerenciamento deve ser adotado. Consequentemente, isso definirá a quantidade de energia economizada e a penalização de desempenho do sistema. Eles podem ser agrupados em quatro categorias: *timeout*, preditivo, estocástico e baseado em aprendizagem (YUE et al., 2012; Y. WANG et al., 2011), que serão descritos a seguir.

Para os métodos *timeout* e preditivo, o conceito de Tempo de Equilíbrio (T_E) é necessário. T_E é definido como o tempo mínimo de permanência em um estado de baixo consumo que compense a energia gasta durante as transições de estado. Para o cálculo de T_E, é feito a soma dos Tempos de Transição (T_T) de estado para determinado módulo, como mostra o gráfico 1, que exibe o momento de transição de estado de consumo, assim como destaca os T_T.

Gráfico 1 – Transição de estados de consumo

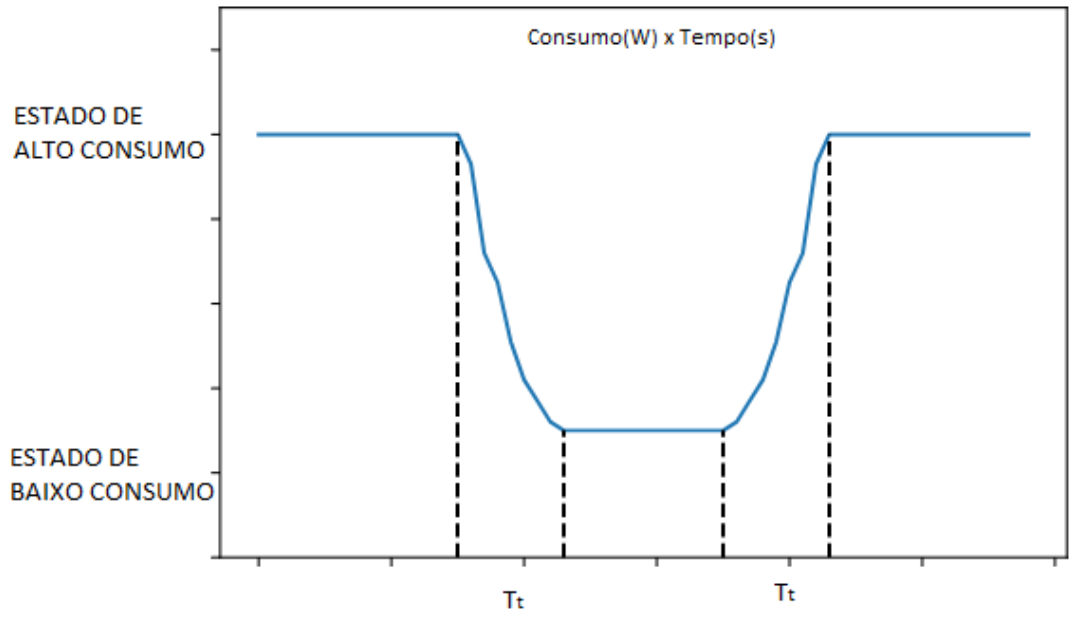

Fonte: Autor

O método de DPM baseado em *timeout* (SIMUNIC et al., 2000; JIANG; XI; YIN, 2010) é amplamente utilizado pelas empresas, como pode ser visto no MS Windows OS e no protocolo IEEE 802.11g. DPM baseado em *timeout* é o método mais fácil de implementar, mas na maioria dos casos apresenta a menor redução no consumo de energia.

Como dito por Simunic et al. (2000), esse método tentará minimizar a dissipação energética detectando a ociosidade do sistema e, após a detecção, o Temporizador de Inatividade (T_I) será iniciado. Após T_I atingir o Tempo Predefinido (T_P) previamente escolhido pelo gerenciador e a ociosidade persistir, o sistema será enviado para um estado de baixo consumo. O fluxograma exibido na Figura 13 exemplifica o funcionamento do DPM baseado em *timeout*.

Figura 13 – Política de *Timeout*

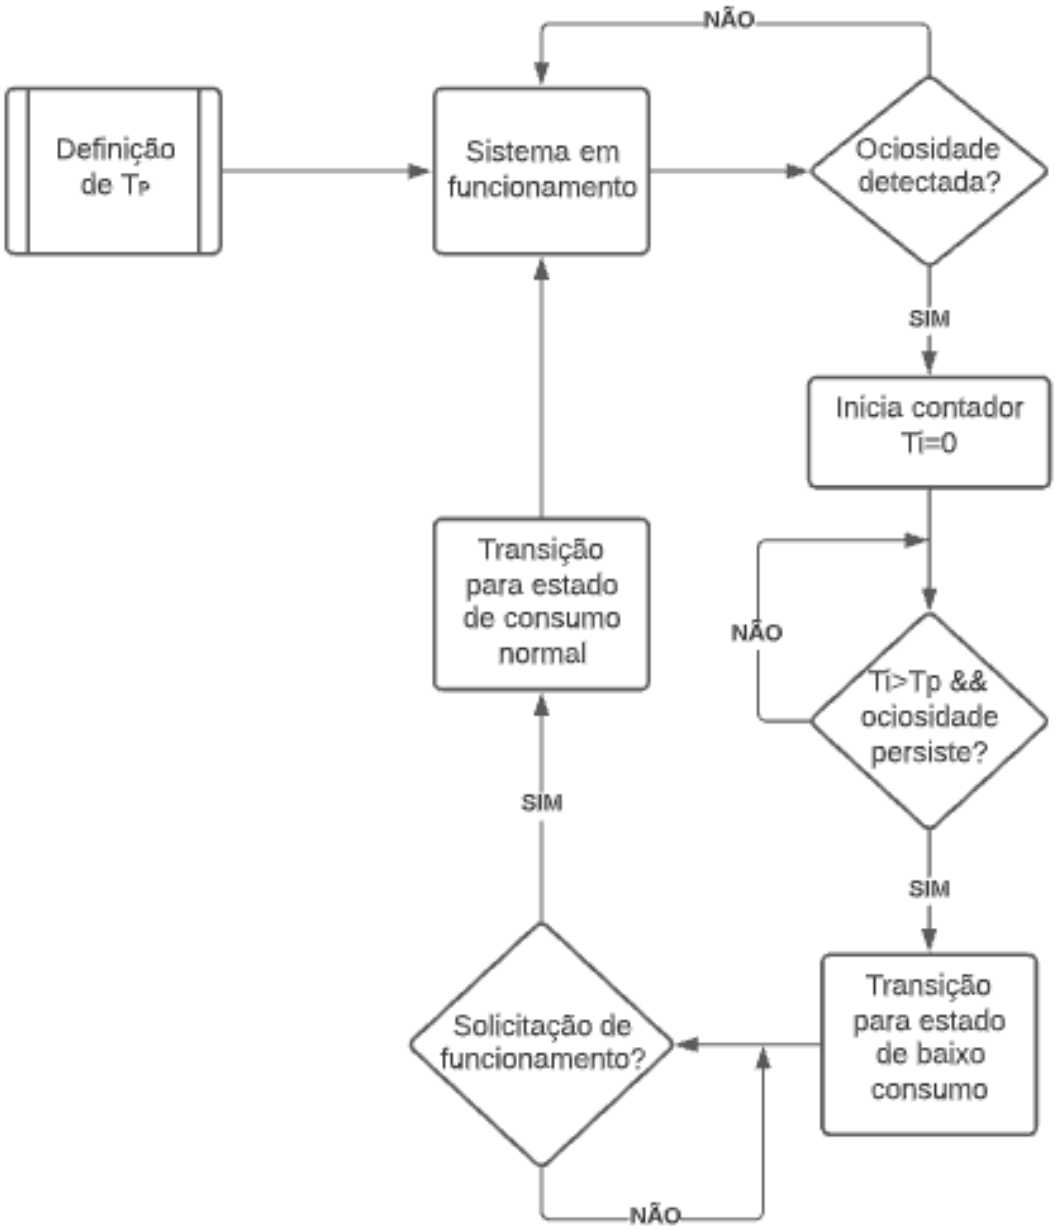

Fonte: Autor

O sistema permanece nesse estado até outra solicitação chegar e quando isso acontecer, deve ser enviado ao estado normal de trabalho.

Para esse método, uma suposição fundamental é que o período ocioso seja maior que o T_P, e que T_P seja superior a T_E.

Essa metodologia tem duas vantagens principais: permite ser facilmente adaptado e consegue atender diferentes sistemas sendo simples de implementar (dependendo ligeiramente

da carga de trabalho), e seu funcionamento pode ser alterado simplesmente variando o valor de tempo predefinido T_P.

Contudo, o esquema de *timeout* apresenta dois problemas principais. O primeiro é a troca de eficiência por simplicidade: um grande T_P pode fazer com que o sistema fique ativo por um tempo desnecessário, o que representa oportunidades perdidas de economia de energia pois há gasto do sistema em espera para T_I alcançar T_P. O segundo ponto está relacionado ao momento em que uma solicitação de trabalho é recebida, pois enquanto ocorre a transição do baixo consumo para o modo de operação normal pode ocorrer uma penalidade de desempenho, enquanto o sistema aguarda a transição de estados ser realizada.

Para resolver os problemas do método *timeout* foi desenvolvido o sistema preditivo (SRIVASTAVA; CHANDRAKASAN; BRODERSEN, 1996; Y.-S. HWANG; KU; K.-S. CHUNG, 2010) que não possui T_P a ser alcançado; o gerenciador de energia, baseado nas informações obtidas *a priori* sobre o sistema, realiza uma predição do próximo período ocioso (T_{p-ocs}), e caso $T_{p-ocs} > T_E$ o gerenciador envia o módulo para estado de baixo consumo. Além disso, (C.-H. HWANG; WU, 2000) propõe a ativação preditiva na tentativa de reduzir a penalidade de desempenho. O gerenciador de energia executará uma ativação preditiva quando o período de inatividade previsto terminar, mesmo se nenhuma solicitação for recebida. Isso pode aumentar o desperdício de energia se o previsto T_{p-ocs} for menor que o real, mas minimizará o atraso da próxima solicitação após o período inativo.

Para definir T_E, o gerenciador de energia terá *a priori* conhecimento da carga de trabalho e, a partir desses dados, analisará se o próximo período inativo será longo o suficiente para atingir T_E.

O fluxograma exibido na Figura 14 exemplifica o funcionamento do DPM preditivo.

Figura 14 – Política preditiva

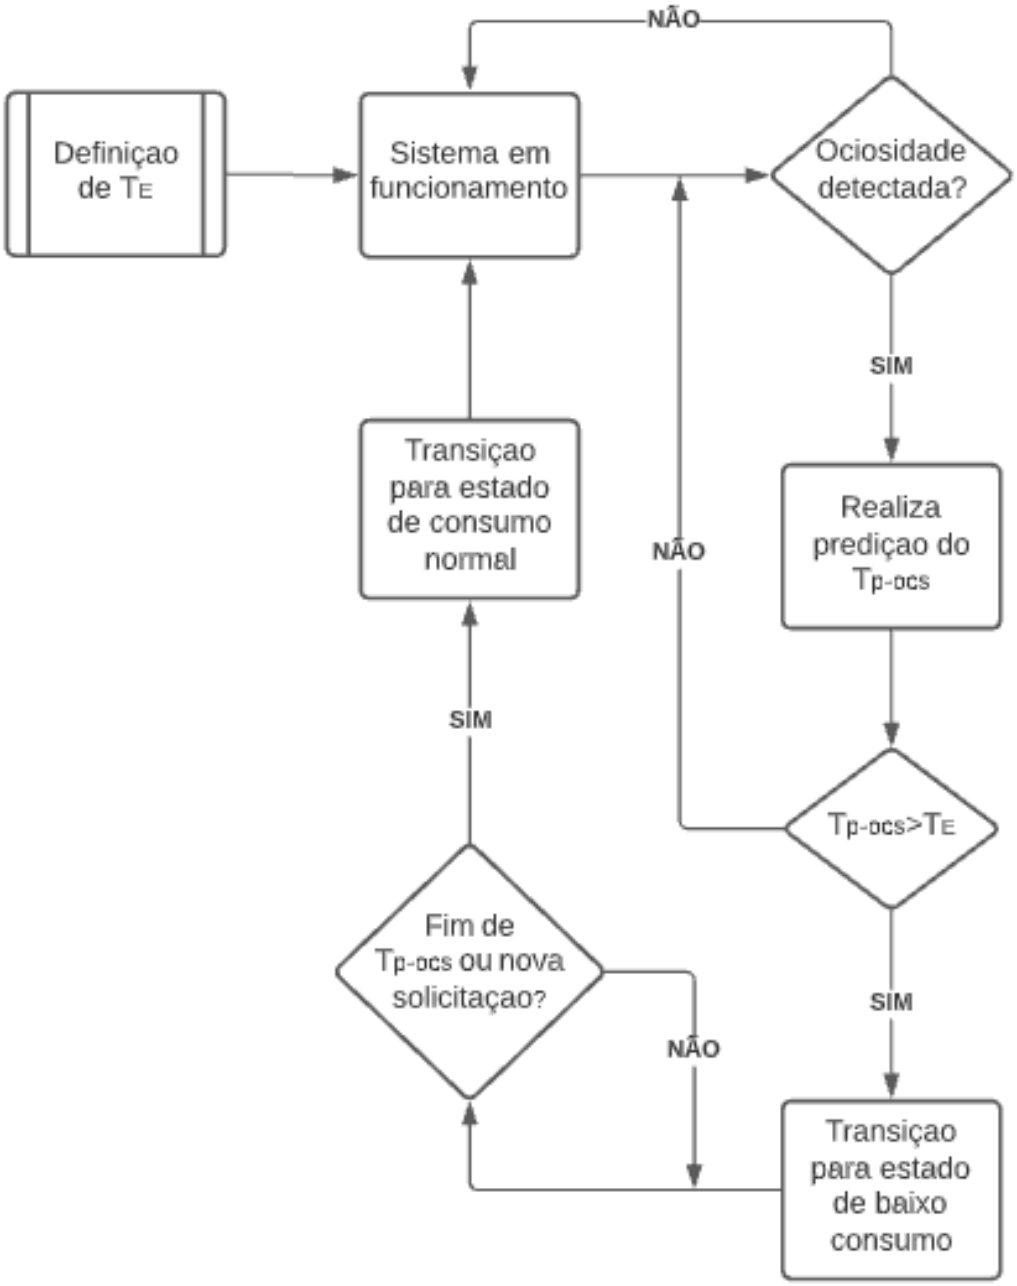

Fonte: Autor

As abordagens de *timeout* e preditivas abordam a incerteza, assumindo que a transição e o tempo de resposta do sistema serão determinísticos. No entanto, o sistema modelado para ser usado nas otimizações de políticas é geral e a generalidade introduz incertezas. Portanto, para um resultado mais preciso, é feita a suposição de um modelo estocástico.

A otimização da política inclui não apenas determinar quando iniciar a transição de estado, mas também para qual estado a transição deve ser realizada.

O método de controle estocástico (BENINI et al., 1999; OKAMURA; DOHI, 2015) aborda os problemas de generalidade e otimização descritos acima. Em vez de tentar fazer previsões para eliminar toda a incerteza, a otimização de políticas é formulada como um problema de otimização sob incerteza.

A abordagem estocástica foi estudada com base nos processos de decisão markovianos (E.-Y. CHUNG et al., 2002), assumindo que o comportamento do sistema bem como a carga de trabalho, possam ser modelados como cadeias de Markov, que são um caso particular de processos estocásticos com estados discretos, com a propriedade de que a distribuição de probabilidade do próximo estado dependa apenas do estado atual e não na sequência de eventos que precederam.

O trabalho de Zhiyuan Ren, Bruce H Krogh e Radu Marculescu (2005) traz a informação que um sistema de gerenciamento de energia pode ser interpretado como um problema de decisão sequencial sob incerteza e através de modelo Markoviano. A formulação funciona do seguinte modo:

O sistema é modelado como uma cadeia de Markov discreta no tempo, denotada por $S = \{S_n,n \geq 1\}$, com o espaço de estados do sistema $\Sigma = \{\alpha_1, \alpha_2, \cdots ,\alpha_m\}$. A cada momento de decisão $n \geq 0$, uma ação de transição de modo de funcionamento U_n é tomada de um espaço de ações A e aplicado à cadeia de Markov. A(ϕ)) é o conjunto de ações disponíveis para o sistema em um estado $\alpha \in \Sigma$. Caso uma ação $U_n = \alpha \in A(\phi)$ seja tomada em um estado $S_n = \phi$, um consumo energético $f(\phi,\alpha)$ ocorre em conjunto com uma serie de medidas de desempenho $f^1(\phi,\alpha), f^2(\phi,\alpha), f^3(\phi,\alpha) \cdots f^n(\phi,\alpha)$; e então, o sistema transita para o estado $S_{n+1} = \phi' \in \Sigma$ com probabilidade $p^\alpha(\phi,\phi')$.

Uma politica c é um mapeamento $c : \Sigma \rightarrow P(A)$, onde $P(A)$ denota o conjunto de todas as distribuições probabilísticas sobre um conjunto finito A. Sob a politica c, a ação $\alpha \in A(\phi)$ é aplicada no sistema com probabilidade $[c(\phi)]_\alpha$, quando sistema está no estado $\phi \in \Sigma$.

O consumo em longo período sob a politica c é:

$$J_f(c) = \lim_{N\rightarrow\infty} E^{S_0,c}\left\{\frac{1}{N}\sum_{n=0}^{N-1}[f(S_n,U_n)]\right\}$$

.

Os recentes avanços em tecnologias de processamento de dados possibilitaram a utilização de técnicas de aprendizado de máquina para treinar um gerenciador.

Segundo Mitchell et al. (1997), o aprendizado de máquina é uma área da inteligência artificial em que são estudados algoritmos computacionais que melhoram automaticamente por meio de experiência.

De acordo com Mohri, Rostamizadeh e Talwalkar (2018), partindo de dados adquiridos *a priori*, algoritmos têm como objetivo generalizar a resolução de problemas a partir de iterações, com a finalidade de tomar a decisão correta em situações não enfrentadas anteriormente.

Os métodos baseados em aprendizado de máquina podem ser usados para decidir quando alterar o estado do consumo de energia, como é feito em (GUO et al., 2018). A pesquisa utiliza aprendizado por reforço para desenvolver um gerenciador capaz de executar aprendizagem e gerenciamento de energia, de maneira contínua e baseada em eventos. Com isso, é capaz de conseguir gerar a previsão da carga de trabalho para fornecer informações parciais sobre o estado da solicitação de serviço para o gerenciador. Além disso, outras técnicas de aprendizado de maquina podem ser utilizadas para o gerenciamento de energia, como' Brand et al. (2020) que traz o gerenciamento de energia em *smartphones* através de redes neurais prevendo o consumo energético a partir do trafego de dados, ou Kong et al. (2006a), que propõe a utilização de algoritmos genéticos para prever a duração de períodos ociosos.

O trabalho de Guo et al. (2018) traz um método de DPM baseado em aprendizado por reforço com o algoritmo *Q-learning* aplicado em um *Data Center*.

Aprendizagem por reforço é o estudo de planejamento e aprendizagem em um cenário em que um agente interage ativamente com o ambiente para atingir um determinado objetivo. Uma representação genérica do cenário de aprendizado por reforço é exibida na Figura 15.

Este é um aprendizado não supervisionado, em que o agente coleta informações através de ações que interagem com o ambiente. Como resposta à interação o agente recebe o estado resultante, assim como uma recompensa. O objetivo do agente é maximizar a recompensa, e consequentemente, o melhor curso de ações a serem tomadas ou política.

Figura 15 – Representação genérica de aprendizado por reforço

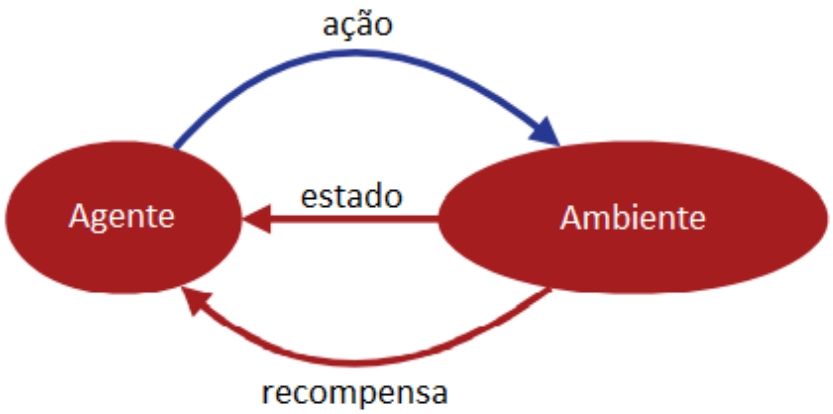

Fonte: o Autor "adaptado de"Mehryar Mohri, Afshin Rostamizadeh e Ameet Talwalkar (2018)

O algoritmo de aprendizado por reforço baseado em *Q-learning* se trata da atualização do valor Q através de iterações entre agente e ambiente feita pela equação abaixo, onde s representa o estado, a representa ação, e t a iteração atual, $\varepsilon_t(s_t,a_t)$ define a taxa de aprendizado, e γ indica o fator de desconto, que diminui o peso de recompensas distantes do agente.

$$Q(s,a) \leftarrow Q(s_t,a_t) + \varepsilon(s_t,a_t)[r_t + \gamma max Q(s_{t+1},a_{t+1}) - Q(s_t,a_t)]$$

Além dos métodos de gerenciamento, existem os seletores, no qual o gerenciador de energia possui um conjunto de políticas já testadas, cada uma com um bom desempenho para uma determinada carga de trabalho. Assim, escolherá a mais adequada de acordo com as necessidades atuais do sistema. O trabalho de Dhiman e Rosing (2006) traz um gerenciador de políticas que, ao final de cada período de ociosidade, compara os desempenhos das políticas para a mesma situação, e a comparação é utilizada para refinar o gerenciador (DHIMAN; ROSING, 2006).

2.2.3 Implementação

Para que um sistema seja adequado ao recebimento do gerenciamento dinâmico de energia, uma característica importante é poder alternar o estado de consumo de energia de seus módulos com base nos sinais do gerenciador.

Os componentes e circuitos do sistema devem suportar o controle em diferentes estados de energia e poder se comunicar com o software responsável por controlar as transições de estado, de acordo com a decisão do controlador de energia (CHEN et al., 2003).

Em Marcu e Tudor (2011), é proposto um modelo para o desenvolvimento de sistemas gerenciáveis de energia dinâmica.

A estrutura sugerida é dividida em 3 camadas: a camada de Aplicativo *Power-Aware*, onde estão presentes os módulos que serão gerenciados; a Estrutura de Energia, que tem a função de monitorar tanto os dados do sistema através de sensores diversos, quanto os estados dos módulos, que são adquiridos pelos *App Profilers*; e o Sistema Operacional, em que as decisões são tomadas conforme mostrado na Figura 16.

Figura 16 – *Framework* para DPM.

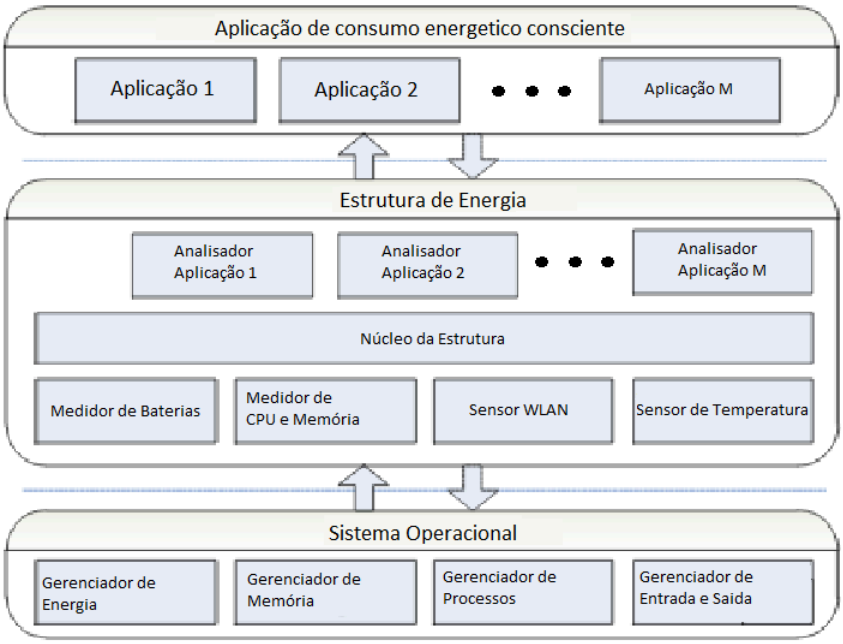

Fonte: o Autor "adaptado de"Marius Marcu e Dacian Tudor (2011)

Traçando um paralelo entre a Figura 16 e um sistema robótico móvel de serviço, a primeira camada (Aplicativo *Power-Aware*) são os módulos, tanto atuadores quanto sensores, que estão sendo gerenciados no momento. A segunda camada (Estrutura de Energia) é onde são realizadas as medições de consumo energético através de sensores de tensão, corrente e tarefas sendo executadas para serem utilizadas na determinação de políticas de gerenciamento que serão usadas. Já na terceira camada (Sistema Operacional), o gerenciador de energia realiza as tomadas de decisões e controla qual acessório será enviado para um estado de baixo consumo e qual deve estar ativo.

3 TRABALHOS RELACIONADOS

Com o propósito de mapear o estado da arte sobre gerenciamento dinâmico de energia aplicado em robôs móveis, foi conduzida uma Revisão Sistemática (KITCHENHAM, 2004), com as questões a serem respondidas: Q1) Qual o nível de gerenciamento energético presente nos robôs móveis? Q2) É possível implementar o gerenciamento dinâmico de energia em um robô móvel?

Os termos utilizados nas buscas foram *"robot"*, *"energy efficient"*, *"dynamic power management"*. Foram encontrados 102 trabalhos.

Como critérios de (I) inclusão e (E) exclusão foram definidos: (I) Trabalhos que estudem sistemas alimentados por baterias; (I) Trabalhos que detalhem o sistema a ser gerenciado; (I) O sistema a ser gerenciado energeticamente deve ser alimentado por baterias; (E) Trabalhos que utilizem múltiplos robôs; (E) Trabalhos que utilizem de variação de frequência de processamento como único método de economia de energia.

Os métodos de exclusão acima foram definidos pois, em um sistema de múltiplos robôs, soluções de energia envolvem a distribuição de tarefas entre os robôs, o que não faz parte do escopo de estudo deste trabalho. Já em sistemas que utilizem de variação de frequência de processamento como único método de economia de energia, são necessários *hardwares* dedicados como Arranjo de Portas Programáveis em Campo (FPGA, *Field Programmable Gate Array*).

Foram levantados 38 trabalhos com aderência ao tema desta pesquisa, e foram classificados como sendo 17 de baixa relevância, 9 de média relevância e 3 com alta relevância.

Dentre os trabalhos de baixa relevância, o foco se estabeleceu em tratar a aplicação de gerenciamento dinâmico de energia, porém não em sistemas robóticos, mas em computadores, carros e bicicletas elétricas (HSU et al., 2016; TRIKI et al., 2013; BABU; A. KUMAR; ROYCHOWDHURY, 2012; CHENG; I. HUANG, 2011; KONG et al., 2006b; REN; B H KROGH; MARCULESCU, 2005; HUNG-MING CHEN et al., 2003). Os trabalhos que apresentam o sistema de gerenciamento de energia de robôs através da recarga de baterias por painéis solares (SHARMA; MISHRA, 2018; GIUSEPPE MARCO et al., 2010), são apresentados apenas sistemas para gerenciar a distribuição e recarga de energia, sem enfoque em eficiência energética (FLOCCHINI; OMAR; SANTORO, 2019; DURMUS et al., 2015; MATHEWS; GOPI, 2014; NAVEAU et al., 2013; MUFFOLETTO et al., 2010; C. WANG; W. HUANG; CHIU, 2009; CRUZ; MATOS, 2008; LUN XIE; QINGYI QIAO; ZHILIANG WANG, 2008).

Os trabalhos de média relevância apresentam os temas de gerenciamento energético de sistemas robóticos através de uma navegação eficiente (HENKEL; BUBECK; XU, 2016; ZHANG; J. HU, 2007; MEI; LU; Y. C. HU, 2005; WEI et al., 2012; HO et al., 2018). Outros estudos evidenciam os sistemas de gerenciamento de energia, por meio do agendamento de momentos para realização de recargas e sequência de tarefas a serem realizadas (BIN WANG et al., 2008; TOMY et al., 2019). Em outro trabalho, um sistema que gerencia a energia de um robô realizando o despertar sob solicitação (AAGELA; AL-JODY; HOLMES, 2018) apresenta a implementação de diversos métodos de DPM, assim como os requisitos para execução (BENINI; BOGLIOLO; DE MICHELI, 2000).

Estes trabalhos mostram pesquisas na área de gerenciamento de energia em robôs utilizando técnicas diferentes do DPM, além disso, um deles traz os requisitos necessários para a implementação do DPM em um sistema.

Sobre gerenciamento energético de sistemas robóticos através de uma navegação eficiente, Henkel, Bubeck e Xu (2016) têm como objetivo gerenciar o consumo de energia de um robô de serviço por meio do planejamento de navegação local, utilizando o método de *Dynamic Window Approach*. O trabalho comprova a eficiência do método, apresentando 9,7% de economia de energia.

Em Zhang e J. Hu (2007) é apresentada uma maneira de um robô móvel economizar energia através do gerenciamento em conjunto, tanto da energia gasta do processador, quanto pelo controle da velocidade de navegação. O trabalho tem resultados que mostram a possibilidade de salvar até 30% mais energia, quando comparado com sistemas que trabalham separadamente a energia gasta pelo processador e controle da velocidade de navegação.

Já em Mei, Lu e Y. C. Hu (2005), é apresentado o estudo do consumo de energia de um robô móvel, baseado na plataforma *PeopleBot*. Foram analisados os sensores juntamente com a navegação, além disso, técnicas de gerenciamento de energia são apresentadas. O trabalho conclui que a navegação é responsável por menos de 50% da energia consumida por um robô. Ademais, conclui que a aplicação de técnicas de gerenciamento de energia em um robô móvel, em conjunto com a otimização de navegação, providenciam grandes oportunidades de redução do consumo energético.

Em Wei et al. (2012), é aprestado um método de planeamento de trajetória eficiente, focado na proposta *staying alive*, que consiste em não deixar o robô ficar sem bateria durante o funcionamento, com uso da realização autônoma de recargas quando necessário. O trabalho

conclui que o método apresentado fornece um planejamento de rota eficaz, no qual o robô permanece ativo e conclui todas as tarefas com o consumo mínimo de energia.

No trabalho Ho et al. (2018), é apresentado um estudo sobre a caracterização e monitoramento de um robô móvel, com o objetivo de desenvolver um gerenciador de atividades para um robô autônomo móvel. Como conclusão, o trabalho determina as métricas que devem ser monitoradas e coletadas, bem como os parâmetros de arquitetura que contribuem para o desenvolvimento do gerenciador de atividades. Inicialmente, é feita a caracterização do sistema para determinar as restrições,ou seja, os requisitos das tarefas a serem realizadas. Em seguida, é iniciada a fase de monitoramento, na qual são feitas aquisições de dados que indicam o estado do sistema. Finalmente, os dados obtidos nas fases anteriores são utilizados para determinar as decisões do controlador de energia. As métricas monitoradas foram o uso do processador, Estado de Carga (SoC, *State of Charge*) tanto da bateria do computador responsável pelo processamento, quanto das baterias do robô, trajetória de navegação e tempo de execução.

Referente a sistemas de gerenciamento de energia através do agendamento em momentos para realizar recargas, e sequência de tarefas a serem realizadas, Tomy et al. (2019) propõe um método que explora o fato de robôs conseguirem aprender a probabilidade de tarefas mais importantes serem requisitadas, e com isso, é possível planejar quando carregar. O trabalho conclui que a metodologia apresentada é conservadora, conseguindo realizar todas as tarefas propostas, sem que a bateria ficasse abaixo de 40% do valor total.

Já Bin Wang et al. (2008) propõe uma técnica de agendamento de tarefas em tempo real com controle de *feedback*, baseado na estratégia de prazo mais curto em primeiro. Os resultados do trabalho mostram que o algoritmo proposto pode estender o tempo máximo de funcionamento sem perda de desempenho.

Sobre o sistema que gerencia a energia de um robô realizando o despertar sob solicitação, Aagela, Al-Jody e Holmes (2018) apresenta uma técnica para ativação apenas quanto requisitado. Isso possibilita que o módulo seja enviado para um modo de baixo consumo enquanto não for necessário operar. O sistema desenvolvido é de fácil aplicação e funcionou corretamente, o que viabilizou a economia de energia quando o robô não está sendo utilizado.

A implementação de diversos métodos de DPM, assim como os requisitos para implementalos, descrita em Benini, Bogliolo e De Micheli (2000) faz uma análise qualitativa entre as diversas abordagens para métodos de DPM. Além disso, o estudo aborda como sistemas empregam componentes passiveis de gerenciamento energético, e como seu uso impacta no consumo geral de energia. Em seguida, são revisadas e comparadas as diferentes abordagens ao DPM, utili-

zando um *framework* para realçar os prós e contras de diferentes políticas de gerenciamento. Finalmente, são apresentados meios para implementação de DPM em sistemas eletrônicos e descritas as iniciativas de padronizar interfaces para possibilitar a utilização DPM controlado via *software*.

Os artigos com alta relevância possuem maior aderência e similaridade com este projeto. A seguir serão discutidos sistemas de gerenciamento de energia em um robô móvel de serviço navegante (SAUZÉ; NEAL, 2013), gerenciamento dinâmico de energia baseado em perfil de um robô móvel de serviço (KERAMIDAS et al., 2020), e o desenvolvimento de um sistema de baixo consumo baseado na tecnologia Sistema no Chip (SoC, *System on Chip*) de detecção de alvo móvel para um robô móvel anfíbio (PAN et al., 2015).

O trabalho de Sauzé e Neal (2013) traz como proposta o gerenciamento de energia em um robô de navegação marítima baseado em redes neurais biologicamente inspiradas, com aquisição de energia baseado em painéis solares, exibido na Figura 17.

Figura 17 – Robô de navegação marítima utilizado em Sauzé e Neal (2013).

Fonte: o Autor "adaptado de"C. Sauzé e M. Neal (2013)

Para tal, foi utilizado um sistema de controle neuroendócrino, que utiliza uma rede neural para controlar os motores responsáveis pela posição dos equipamentos utilizados na navegação do robô. A rede neural pode, então, ser suprimida por um hormônio, cuja concentração aumenta de acordo com a diminuição no nível das baterias, resultando em uma diminuição na

frequência de funcionamento dos atuadores. A rede neural de controle utilizada é exibida na Figura 18.

Figura 18 – Rede neural utilizada para controle.

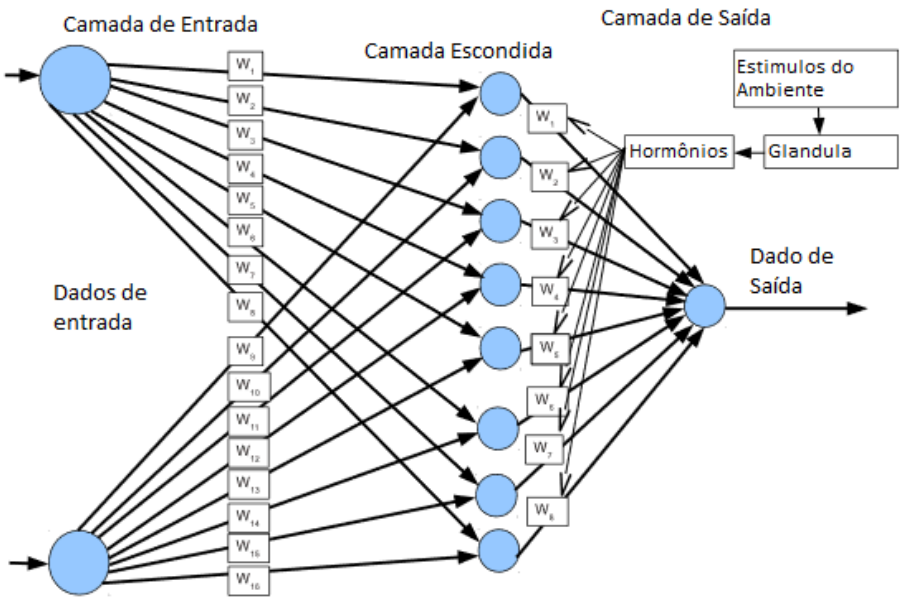

Fonte: o Autor "adaptado de"C. Sauzé e M. Neal (2013)

O conceito definido pelo autor como *Biologically Inspired Control and Power Management* traz a definição de gerenciamento de energia baseado em redes neurais, utilizando o nível das baterias como gatilho para as tomadas de decisões de economia de bateria, sacrificando o rendimento do sistema em função do aumento da vida útil.

Foram realizados experimentos com o hormônio de supressão de atividade fixo e variável. Em simulações os resultados obtidos foram significativos, porém quando levados ao mundo real, os resultados não foram expressivos. A diferença nos resultados se explica pela simplicidade do modelo adotado nas simulações, quando comparada à realidade muito mais complexa e ruidosa que o robô enfrenta.

Para trabalhos futuros, são sugeridos novos experimentos com barcos maiores, podendo permanecer na água por um período maior de tempo. Além disso, ter a adição de novos hormônios, representando variáveis como a distância até o objetivo, estado de agitação do mar, proximidade de obstáculos, entre outros.

O trabalho se mostra importante para esta pesquisa pois apresenta a aplicação de um gerenciamento dinâmico de energia em um robô móvel com resultados positivos, além de demonstrar a técnica de gerenciamento através de controle neuroendócrino.

Keramidas et al. (2020) tem como proposta a exploração de sistemas embutidos de baixo consumo de robótica móvel, com o objetivo de aumentar a vida útil de um robô móvel através de técnicas de economia de energia baseadas em perfil.

Para atingir o objetivo, os autores discretizaram os estados em que o robô pode se encontrar e definiram quais dos seus módulos (sensores, atuadores e comunicação) devem permanecer ligados em cada um dos possíveis estados.

Figura 19 – Perfis previamente definidos e os respectivos estados dos periféricos.

Estado	CPU	FPGA	Sensores	Motores	Rede
Esperando	ON	OFF	OFF	OFF	ON
Navegando	ON	ON	ON	ON	ON
Monitorando	ON	ON	ON	OFF	ON
Monitorando e Carregando	ON	ON	ON	OFF	ON

Fonte: o Autor "adaptado de"G. Keramidas et al. (2020)

A estratégia de gerenciamento se assemelha com o DPM baseado no método preditivo, pois os possíveis estados foram previamente declarados. Assim que o robô entra em um deles, os módulos necessários são ativados e os desnecessários enviados para um modo de baixo consumo energético.

Após os testes, é possível notar uma redução considerável no consumo energético, que se reflete na diminuição do número de cargas necessárias em um determinado período de tempo e na quantidade de horas em que o robô não está disponível para uso, pois está em recarga.

O trabalho mostra que sistemas de gerenciamento energético em robôs móveis baseado em perfil é de grande utilidade, pois foi possível estender consideravelmente o *runtime* do sistema.

Keramidas et al. (2020) é relevante para este trabalho pois na pesquisa são apresentados resultados positivos para a aplicação de DPM baseado em perfil em um robô móvel. O método possui semelhanças com o DPM preditivo, indicando a viabilidade de aplicação em sistemas robóticos móveis.

O trabalho de Pan et al. (2015) propõe o desenvolvimento de um sistema de baixo consumo, baseado na tecnologia SoC, de detecção de alvo móvel para um robô anfíbio. Neste caso,

sendo SoC todos os componentes de um computador, ou qualquer outro sistema eletrônico em um circuito integrado.

Para criação do sistema, foi utilizado o SoC Xilinx Zynq-700, que contém *hardware* que possibilita o gerenciamento do consumo de energia através da aplicação de DPM e Escala Dinâmica de Tensão (DVS, *Dynamic Voltage Scaling*).

Os resultados do trabalho mostram uma economia de aproximadamente 15% da energia consumida, quando comparado com o consumo sem técnicas de gerenciamento de energia. O exemplo pode ser visto na Figura 20, em que são exibidos os resultados da pesquisa.

Figura 20 – Resultados dos métodos de economia de energia.

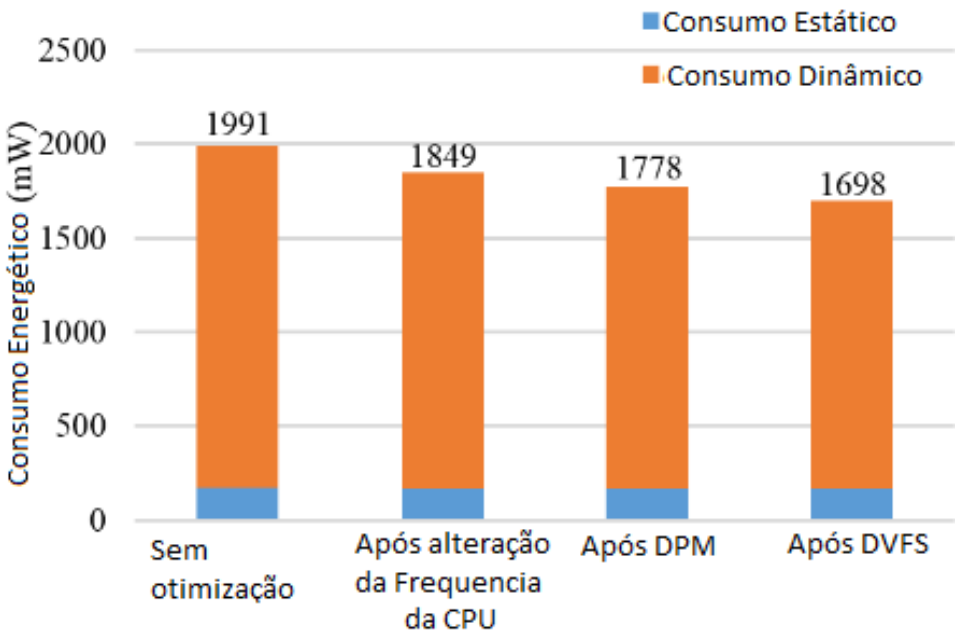

Fonte: o Autor "adaptado de"S. Pan et al. (2015)

O DPM aplicado no sistema, apesar de ser aplicado diretamente no chip, é o mesmo método de gerenciamento de energia que será utilizado neste trabalho. Os resultados positivos apresentados em Pan et al. (2015) reforçam a viabilidade do DPM aplicado em robôs.

4 METODOLOGIA

Este trabalho propõe a modelagem de um sistema de Gerenciamento Dinâmico de Energia em robôs móveis, com objetivo de aumentar o tempo de funcionamento e executar um gerenciamento das baterias. Além disso, neste trabalho será realizada a coleta de informações para que o robô se torne mais inteligente quanto às decisões relacionadas ao sistema de energia e a realização de tarefas. Para isso, os dados de consumo de energia do robô sem DPM foram coletados em um cenário real e os dados do consumo de energia foram simulados utilizando os dados reais.

A seção 4.1 descreve o método seguido por esta pesquisa. A seção 4.2 apresenta o robô e as ferramentas utilizadas. A seção 4.3 apresenta a metodologia utilizada para selecionar quais periféricos do robô teriam seus dados coletados e analisados durante a execução do roteiro. A seção 4.4 mostra o roteiro da tarefa realizada, assim como o método utilizado para a coleta de dados. A seção 4.5 descreve a forma como os dados simulados foram gerados a partir dos dados reais.

4.1 MÉTODOS

O diagrama presente na Figura 21 exibe os passos executados nesta pesquisa, detalhados individualmente em cada um dos quadros.

Figura 21 – Diagrama metodológico

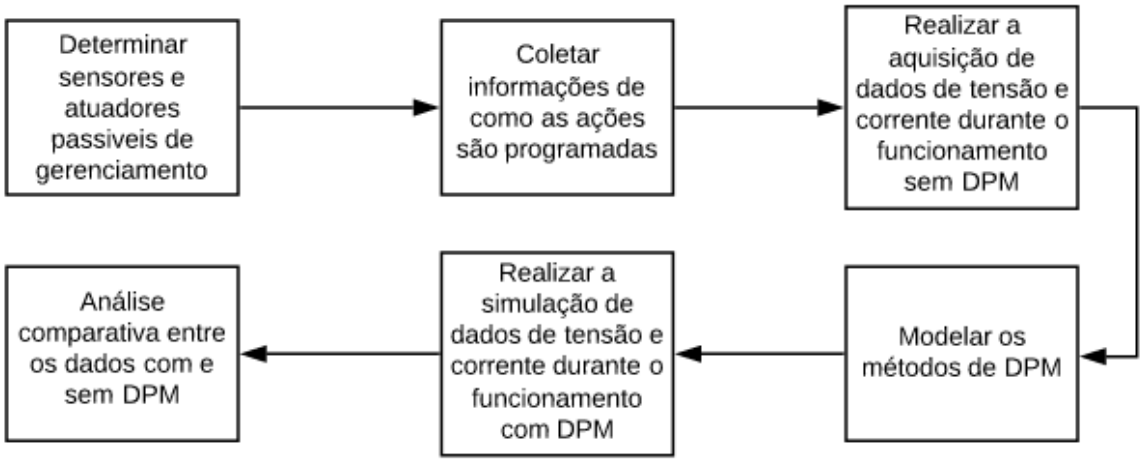

Fonte: Autor

O primeiro passo consiste em determinar quais os sensores e atuadores presentes no sistema, e quais deles apresentam a possibilidade de alterar o estado de consumo energético, ou podem ser desligados e ligados novamente sem que o sistema falhe.

Em seguida, após definidos quais os periféricos gerenciáveis energeticamente, foram coletadas informações de como as ações do robô são programadas, visando determinar quais as informações disponíveis *a priori* para o gerenciador.

Após a coleta das informações previamente disponíveis, a aquisição de dados de consumo energético no sistema foi realizada. Os dados que foram coletados durante a realização de uma tarefa previamente definida são referentes à Tensão e Corrente.

Com as informações disponíveis *a priori*, juntamente aos dados de Tensão e Corrente em função do tempo de cada módulo, foram modelados os Gerenciadores de Energia.

Em seguida foram feitas simulações do consumo energético do sistema ao realizar a tarefa previamente definida utilizando sistemas de gerenciamento de energia.

Finalmente, foi realizada a comparação entre dados colhidos sem o gerenciamento e os simulados com a aplicação dos gerenciamentos, com o objetivo de determinar qual o mais viável a ser aplicado em um robô móvel de serviço.

4.2 ROBÔ HERA

O robô HERA (Figura 22), desenvolvido pela equipe RoboFEI@Home, foi utilizado como base para análise, testes e simulação do DPM tem seus componentes exibidos na Figura 23

Figura 22 – Robô HERA

Fonte: Autor

Figura 23 – Componentes do robô HERA

	Sensor	Atuador	Controlador
Cabeça	Multi-sensor Matrix Creator; 2x Microfone direcional RODE VideoMic GO; Microsoft Kinect (RGBD).	Apple Ipad para interação.	Mini PC Zotak ZBOX-EN-1060K
Torso	Asus Xtion pro (IR).	Braço robótico; Som	
Base	Laser Hokuyo UTM-30LX-EW "Top-URG".	Base Omnidirecional.	

Fonte: Autor

As principais ferramentas utilizadas foram:

a) **Arduino**: Uma plataforma eletrônica de código aberto baseada em hardware e software de uso simples.

b) ***ROS***: A principal ferramenta utilizada neste projeto é a plataforma Sistema Operacional Robótico (ROS, *Robot Operating System*). O ROS é um framework que auxilia na escrita de software para robôs, possuindo uma coleção de ferramentas, bibliotecas e convenções com o objetivo de simplificar a criação de programas para tarefas complexas e robustas em robôs independentes da plataforma.

c) **Fontes de alimentação DC**: Equipamento usado para alimentar cargas elétricas.

d) **Sensor ACS712**: Sensor de corrente.

4.3 ANÁLISE DO SISTEMA

Do estudo do robô HERA, foi gerado o mapeamento dos componentes eletrônicos presentes, suas interconexões e fontes de energia. A partir do mapeamento foi gerado o esquemático mostrado na Figura 24.

Na Figura, as linhas vermelhas representam conexões de energia, as azuis de comunicação, e as roxas indicam que tanto a comunicação quanto a alimentação estão na mesma conexão. As caixas vermelhas indicam fontes de alimentação, as amarelas os módulos candidatos a serem gerenciados energeticamente e as pretas representam partes do sistema que, ou são reguladores de tensão, ou não podem sofres restrições operacionais.

Os módulos candidatos ao gerenciamento são:

a) Monitor frontal

b) Base

c) Monitor traseiro

d) Caixa de som

e) Manipulador

f) Laser Frontal

Dentre eles, o monitor frontal e o manipulador não podem ser gerenciados. O primeiro, por ser um Apple Ipad, tem sistema de energia integrado, impossibilitando a captação de dados. O segundo possui um sistema próprio de regulação de tensão e comunicação, como pode ser visto na Figura 24, que não fornece opções de diferentes modos de consumo.

Os módulos disponíveis para captação de dados no robô são: base, som, laser e monitor traseiro. Para este trabalho, foi preparada uma tarefa onde todos foram utilizados, com o intuito de padronizar os dados da corrente em função do tempo observados. Feito isso, os dados disponíveis para análise são: Tensão e Corrente em função do tempo de cada módulo.

Figura 24 – Resultado do mapeamento do robô HERA

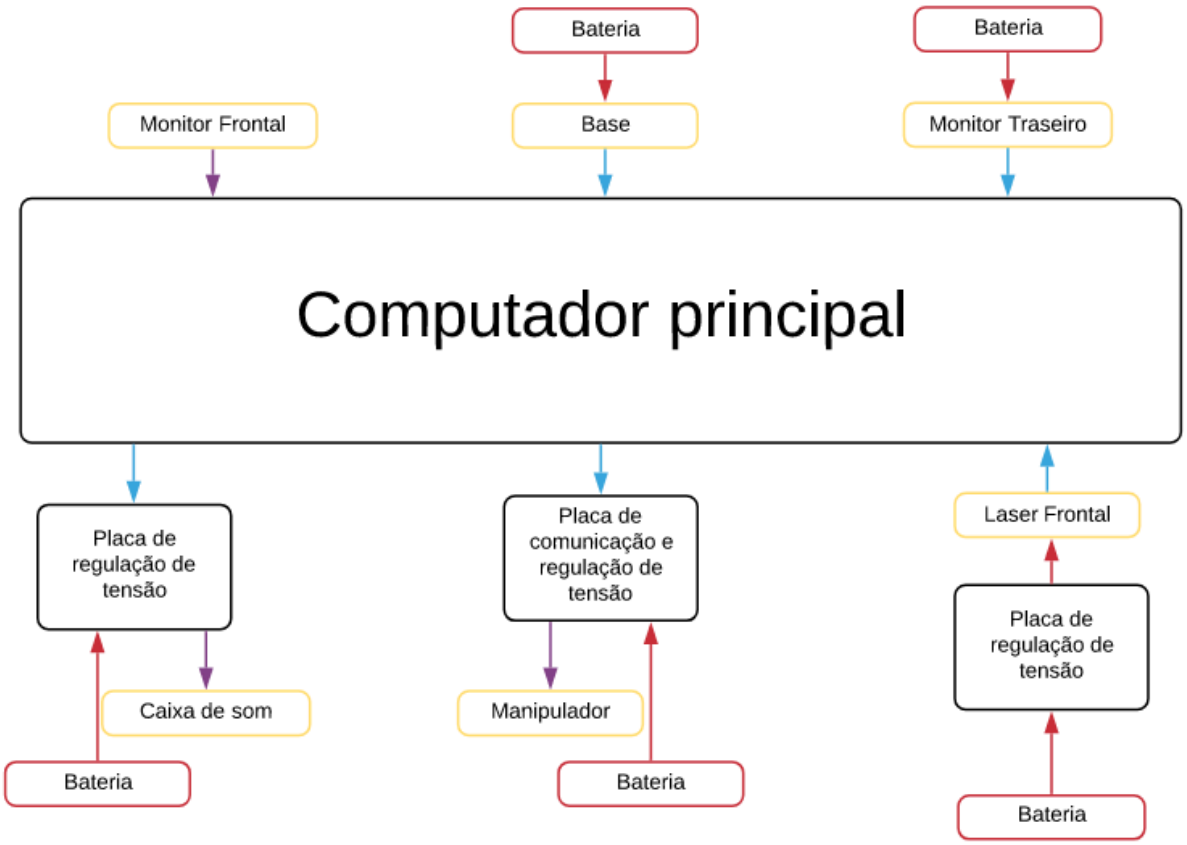

Fonte: Autor

Com o estudo de como o robô é programado, é possível extrair o momento no qual cada um dos módulos será requisitado.

4.4 ROTEIRO DA TAREFA E MÉTODO DE ANÁLISE

A tarefa desenvolvida para esta pesquisa consiste em: O robô HERA, inicialmente no ponto inicial, se apresenta, navega até encontrar a estação, avisa que chegou e que retornará, e volta ao ponto inicial.

A tarefa explora todos os módulos disponíveis para análise, como mostra a Figura 27, que exibe o fluxograma da tarefa proposta, assim como uma análise referente a ociosidade de cada módulo durante cada etapa da tarefa. Durante o experimento, foi feita a coleta da corrente de funcionamento de cada um dos módulos em função do tempo, assim com o tempo total de execução da tarefa.

As baterias normalmente utilizadas pela equipe RoboFEI@Home para alimentar o sistema, exibidas na Figura 25, não foram utilizadas nesta tarefa, pois, além de possuírem capacidades diferentes, seus SoH (indicador da vida útil baseado na capacidade restante comparada à original) variam, como pode ser visto na Figura 26, que apresenta dados das capacidades originais e restantes referentes às baterias da Figura 25, assim como seus SoH. Os dados foram adquiridos após a realização de testes nos quais as baterias tiveram suas capacidades verificadas empiricamente, inicialmente sendo descarregadas e em sequencia carregadas, para estimar a capacidade de carga restante, e assim obter o SoH.

Figura 25 – Baterias utilizadas pela equipe RoboFEI@Home

Fonte: Autor

Figura 26 – Baterias e seus respectivos SoH

BATERIA	Capacidade Restante	Capacidade Original	SOH (%)
1	2952	4300	68.65
2	3980	5000	79.60
3	4163	5000	83.26
4	5173	5200	99.48

Fonte: Autor

Para uma análise consistente de dados, foram utilizadas fontes DC para alimentação dos módulos analisados. Isso garante que os dados de corrente utilizados para análise dos diferentes métodos de DPM não sejam alterados pela variação dos SoH das baterias.

Figura 27 – Fluxograma da tarefa sendo realizada

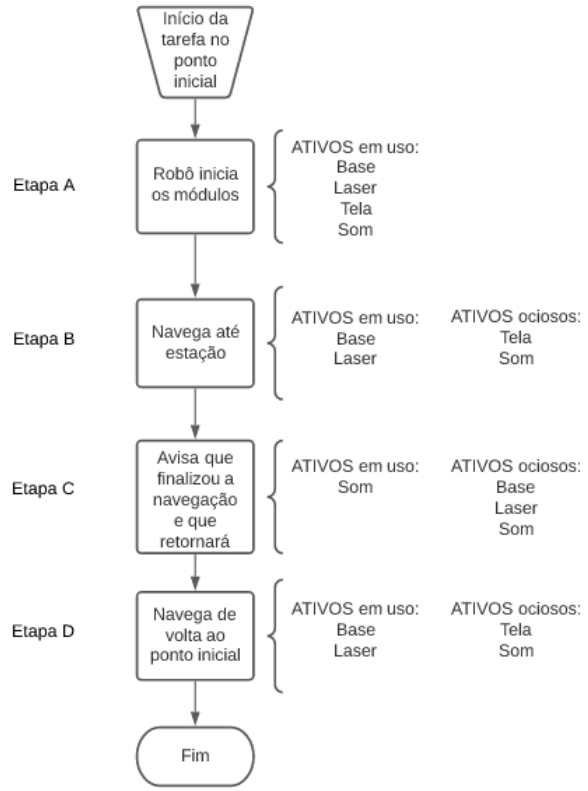

Fonte: Autor

Para a aquisição dos dados de corrente, o esquemático mostrado na Figura 28 exibe a conFiguração que será utilizada. Os fios representando o positivo e o negativo da fonte de alimentação DC são exibidos em vermelho e preto, respectivamente. O fio positivo é conectado ao sensor de corrente e o do sensor é conectado no modulo analisado. O negativo da fonte é conectado diretamente no módulo.

Figura 28 – Sistema de captação de dados

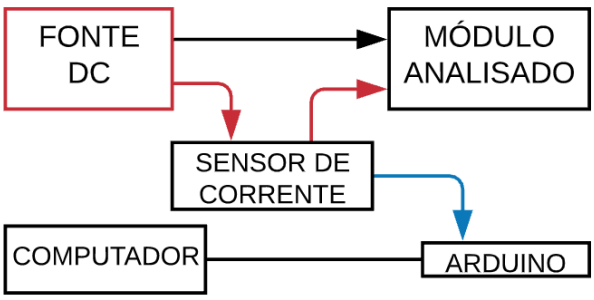

Fonte: Autor

Os dados adquiridos pelos sensores foram enviados para o computador através de um Arduino, que foi responsável pela interpretação e armazenamento dos dados. O sensor utilizado foi o ACS712 (ALLEGRO MICROSYSTEMS, 2006).

4.5 SIMULAÇÃO

Para a simulação dos métodos de DPM, os dados de funcionamento sem gerenciamento foram utilizados. A execução dos passos das tarefas se deu a partir da simulação de uma maquina de estados, definidos por Ndjountche (2016) como sistemas compostos por seções lógicas combinatórias e sequenciais, simulando a estrutura de programação utilizada pela equipe RoboFEI@Home. A maquina de estados simulada pode ser exemplificada pela figura 29, onde os estados A, B, C e D apresentados são os mesmos da figura 27, e a variável X usada para determinar o fim ou não de cada um dos estados. Os estados de consumo utilizados foram binários, onde ou o consumo do sistema seria igual ao sistema sem gerenciamento, ou não existe consumo energético. Para as transições, as de ativo para inativo são imediatas, e as de inativo para ativo foram coletadas no inicio do experimento para cada um dos módulos, e foram utilizadas como a transição de estado. Os tempos de transição de cada módulo são exibidos na Figura 30.

Figura 29 – Maquina de estados simulada neste trabalho.

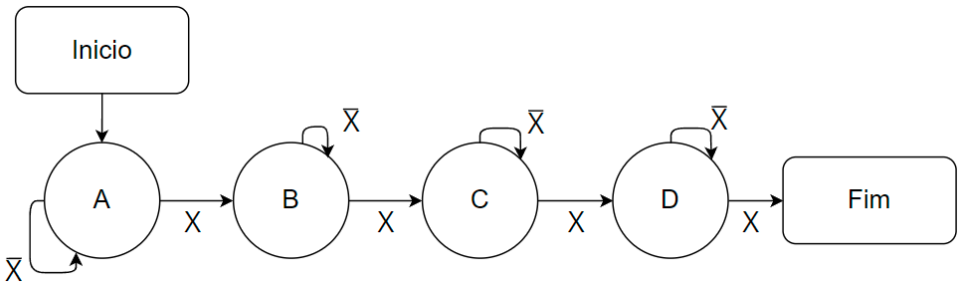

Fonte: Autor

Figura 30 – Módulos analisados e seus tempo de transição

Módulo	Tempo de transição (s)
Base	0
Laser	3
Som	1
Tela	2

Fonte: Autor

5 RESULTADO

A Potencia ativa (W) individual de cada módulo é calculado ao se multiplicar a corrente (A) coletada pelo sensor, pela tensão das fontes de alimentação (V), que são mostradas na Figura 31. Com os novos valores, foi feito o gráfico do consumo energético em função do tempo, exibido no gráfico 2, que foi dividido em 4 faixas, A B C e D, que representaram as 4 etapas da tarefa, descrita na Figura 27.

Figura 31 – Módulos analisados e a tensão de suas respectivas fontes de energia.

MÓDULO	TENSÃO (V)
Base	24
Laser	12
Som	24
Tela	12

Fonte: Autor

A partir do gráfico é possível identificar o consumo constante durante toda a tarefa, tanto pela tela quanto pelo laser. O som, apesar das variações apresentadas, consome energia de maneira relativamente regular. Ao analisar o resultado da base, destacam-se os picos de consumo, decorrentes do alto esforço dos motores para iniciar o movimento.

A partir dos dados obtidos foram calculados o Consumo Médio por Segundo (C_{ps}, [W/s]),Tempo de Execução (T_{Exec}, [s]), e Consumo Total (C_T, [W]). O sistema atual levou 98 segundos para finalizar a tarefa, com um consumo médio de 40,494 W/s, e um consumo total de 3968,412 Watts.

Um sistema ideal é caracterizado por ser um sistema que detecta a ociosidade no instante inicial e transita imediatamente para o estado de baixo consumo. Caso seja requisitado novamente, é instantaneamente enviado para o modo normal de funcionamento. Transições de estado são imediatas e não apresentam gasto energético.

Considerando o sistema analisado como ideal, o consumo mínimo possível obtido com DPM é mostrado no gráfico 3, que apresenta o consumo de cada modulo, assim como o consumo total. O sistema ideal levaria 98 segundos para finalizar a tarefa, com um consumo médio de 23,128 W/s, e um consumo total de 2266,544 Watts.

Gráfico 2 – Consumo de cada módulo e consumo total.

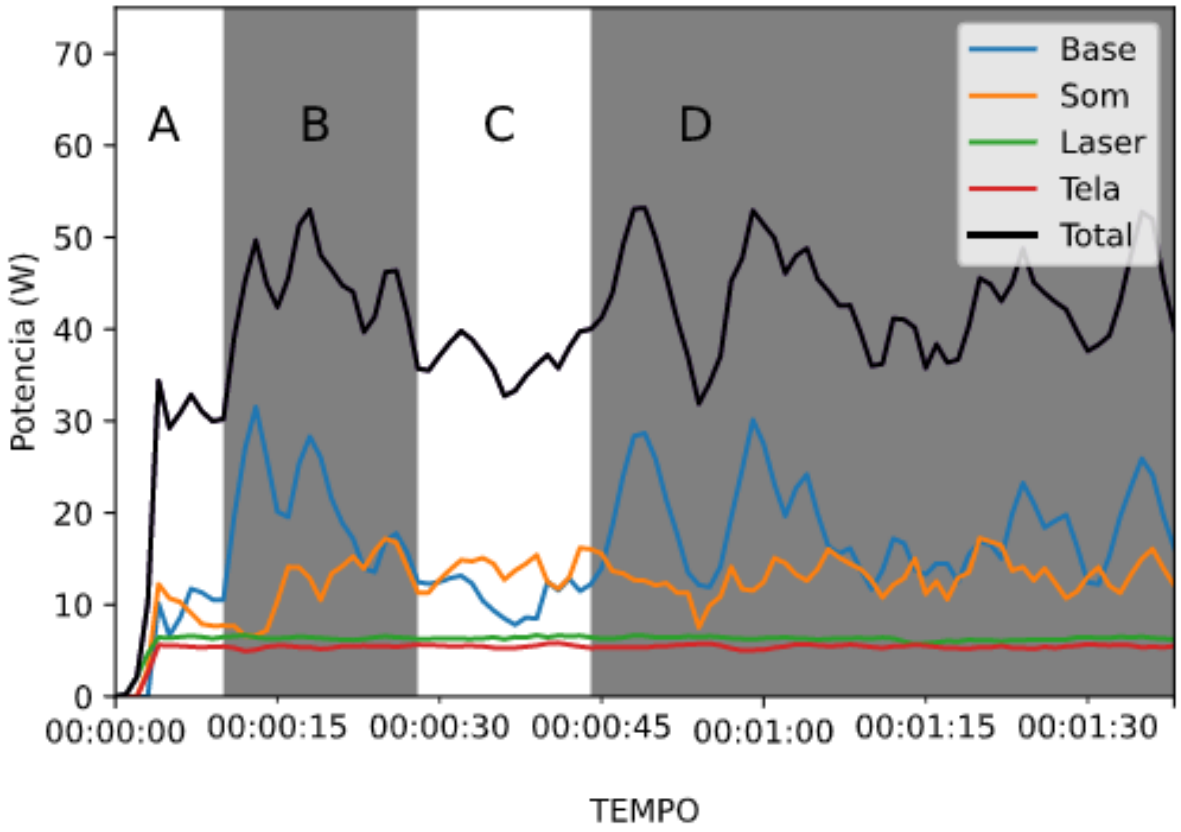

Fonte: Autor

Gráfico 3 – Consumo ideal de cada módulo e consumo ideal total.

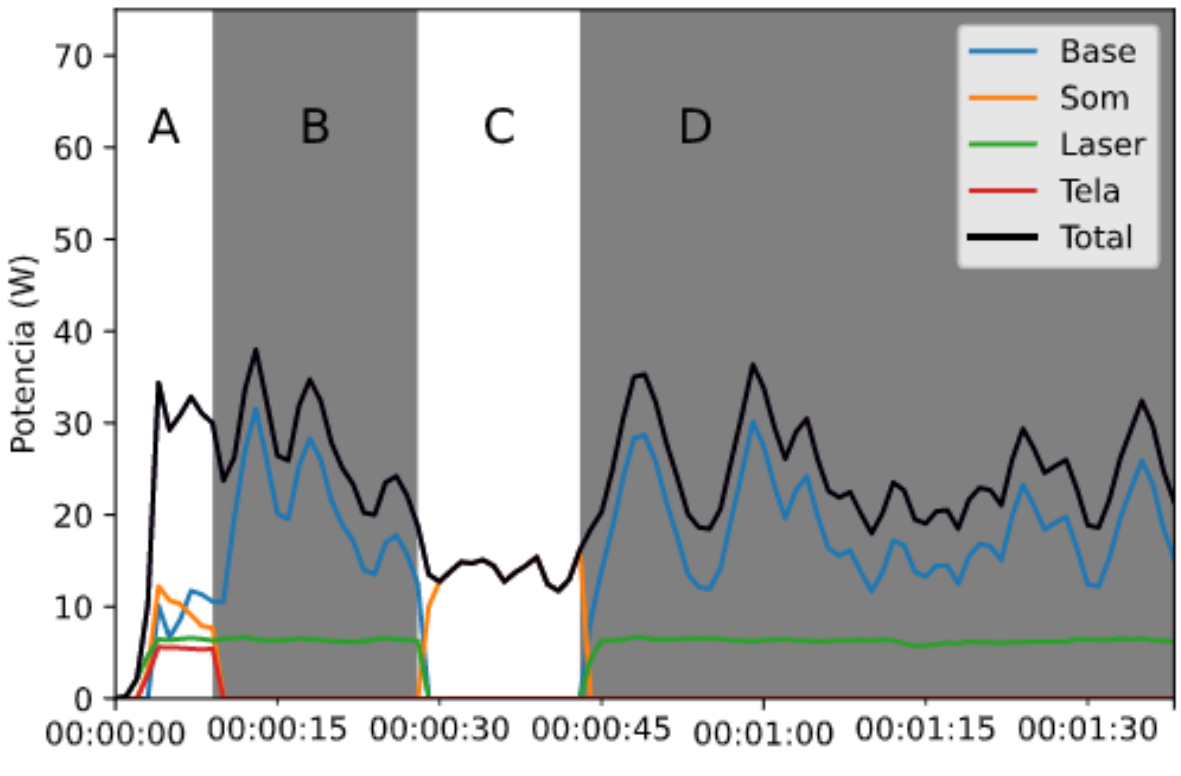

O diferencial do método ideal pode ser analisado nos momentos de transição. Ao mudar do estado A para o estado B, os módulos ociosos (Tela e Som) são instantaneamente enviados para um estado onde não existe consumo de energia. No momento de transição de B para C, os módulos ociosos (Base e Laser) são instantaneamente enviados para um estado onde não existe consumo de energia, e o requisitado (Som) é instantaneamente ativado quando requisitado. Todas as transições seguem este padrão.

Com os dados obtidos, foi feito o cálculo da energia consumida durante a realização da tarefa, e então definidas as políticas de DPM. Neste trabalho foram analisadas as políticas de *Timeout* e Preditivo.

5.1 POLÍTICA DE *TIMEOUT*

Este método minimiza a dissipação energética detectando a ociosidade do sistema e, após a detecção, o Temporizador de Inatividade (T_I) é iniciado. Após T_I atingir o Tempo Predefinido (T_P) e a ociosidade persistir, o sistema será enviado para um estado de baixo consumo. Neste teste, foi utilizado T_P=2s e o consumo simulado é mostrado no gráfico 4, contendo o consumo simulado de cada módulo, executando a tarefa com a politica de *timeout* aplicada.

Neste método, ao mudar do estado A para o estado B, os módulos ociosos (Tela e Som) aguardam o tempo T_P, e após isso, são enviados para o modo de baixo consumo. No momento de transição de B para C, os módulos ociosos (Base e Laser) aguardam o tempo T_P , e após isso, são enviados para o modo de baixo consumo, e o requisitado (Som) transita entre desligado e pronto para funcionar quando requisitado, seguindo o tempo de transição mostrado na Figura 30. Todas as demais transições seguem este padrão. O sistema com o método *timeout* de 2 segundos levou 102 segundos para finalizar a tarefa, com um consumo médio de 24,5 W/s, e um consumo total de 2499 Watts.

Gráfico 4 – Consumo de cada módulo e consumo total com DPM *timeout* aplicado.

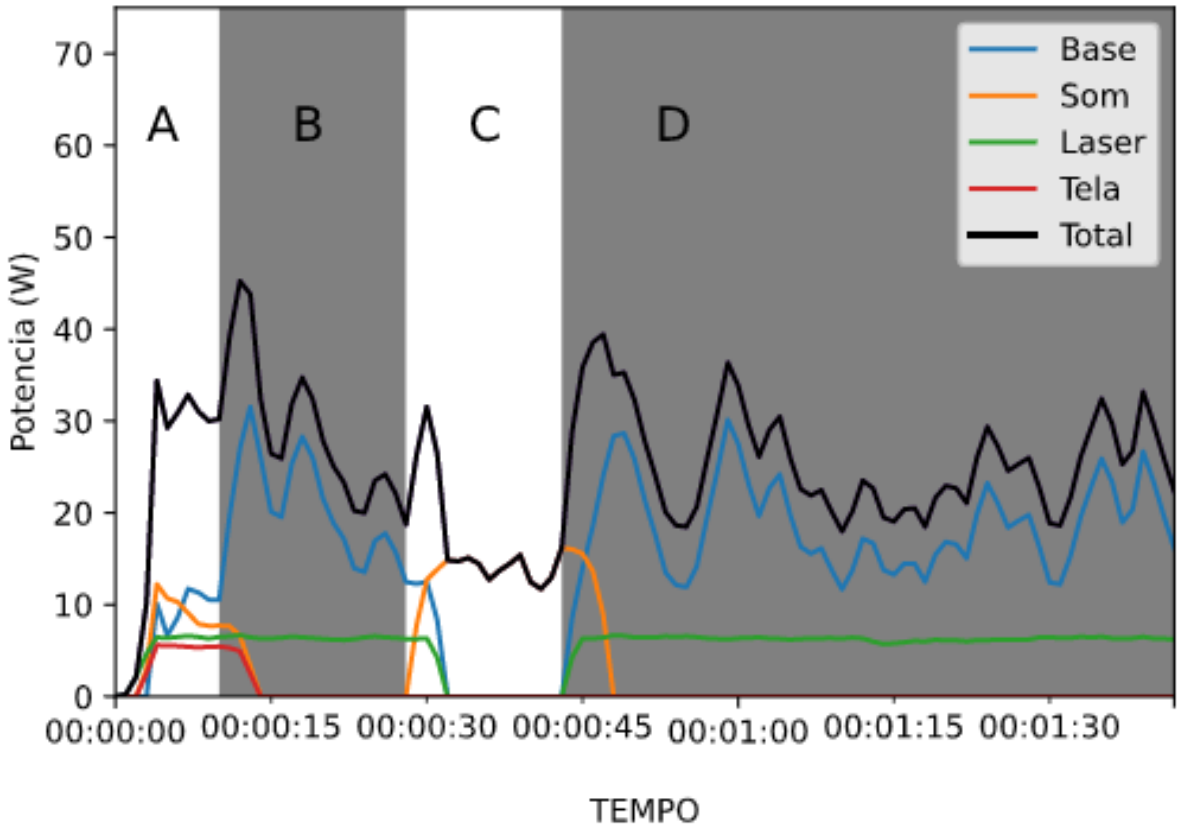

Fonte: Autor

5.2 POLÍTICA PREDITIVA

Nesta política, o gerenciador de energia, baseado nas informações obtidas *a priori* sobre o sistema, realiza uma predição do próximo período ocioso (T_{p-ocs}), e caso $T_{p-ocs} > T_E$, o gerenciador envia o módulo para estado de baixo consumo.

Como demonstrado por Keramidas et al. (2020), robôs móveis podem sempre considerar $T_{p-ocs} > T_E$ para seus módulos, pois geralmente a duração do robô em cada estado é significativamente maior do que o tempo de transição. A afirmação é apoiada pelo fato de, no robô analisado, o maior tempo de transição ser de 3 segundos, comparado com os 3000 segundos determinados como limite de tempo para realização de provas no campeonato mundial de robótica de serviço (MATAMOROS et al., 2019), realizado pela RoboCup. Como foi adotado T_{p-ocs} sempre maior que T_E, os módulos são enviados imediatamente ao estado de baixo consumo no momento de detecção da ociosidade.

Ao mudar do estado A para o estado B, os módulos ociosos (Tela e Som) são instantaneamente enviados para um estado onde não existe consumo de energia. No momento de transição de B para C, os módulos ociosos (Base e Laser) são instantaneamente enviados para um estado onde não existe consumo de energia, e o requisitado (Som) transita entre desligado e pronto para funcionar quando requisitado, seguindo o tempo de transição mostrado na Figura 30. Todas as demais transições seguem este padrão. O sistema com método preditivo levaria 102 segundos para finalizar a tarefa, com um consumo médio de 23 W/s, e um consumo total de 2346 Watts.

O gráfico 5 apresenta o consumo de cada módulo e o consumo total com o método preditivo aplicado.

Gráfico 5 – Consumo de cada módulo e consumo total com DPM preditivo aplicado.

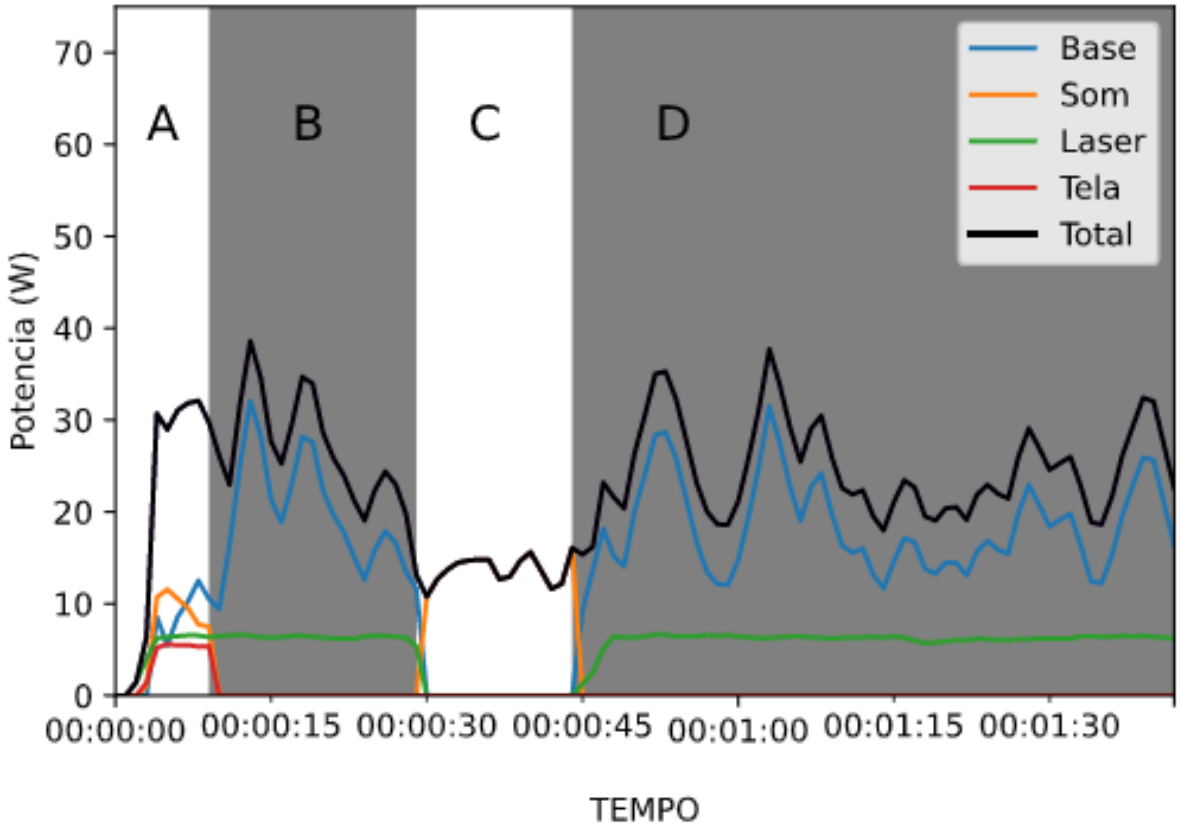

Fonte: Autor

Ainda no método preditivo, C.-H. Hwang e Wu (2000) propõe a ativação preditiva na tentativa de reduzir a penalidade de desempenho. O gerenciador de energia executará uma ativa-

ção preditiva quando o período de inatividade previsto terminar, mesmo se nenhuma solicitação for recebida.

O diferencial da ativação preditiva pode ser visto na transição de B para C com o módulo Som, que começa a transição de inativo para ativo antes de ser requisitado, com o objetivo de estar pronto para utilização no momento da requisição de funcionamento. O mesmo comportamento pode ser visto na transição de C para D com os módulos Laser e Base, que apresentam o mesmo comportamento de ativação previa para estarem prontas no momento da requisição. O sistema com método preditivo e reinicio prévio levaria 98 segundos para finalizar a tarefa, com um consumo médio de 23,351 W/s, e um consumo total de 2288,398 Watts. O gráfico 6 apresenta o consumo de cada módulo e o consumo total com o método preditivo aplicado, e tendo os módulos com ativação previa.

Gráfico 6 – Consumo de cada módulo e consumo total com DPM preditivo e reinicio prévio aplicado.

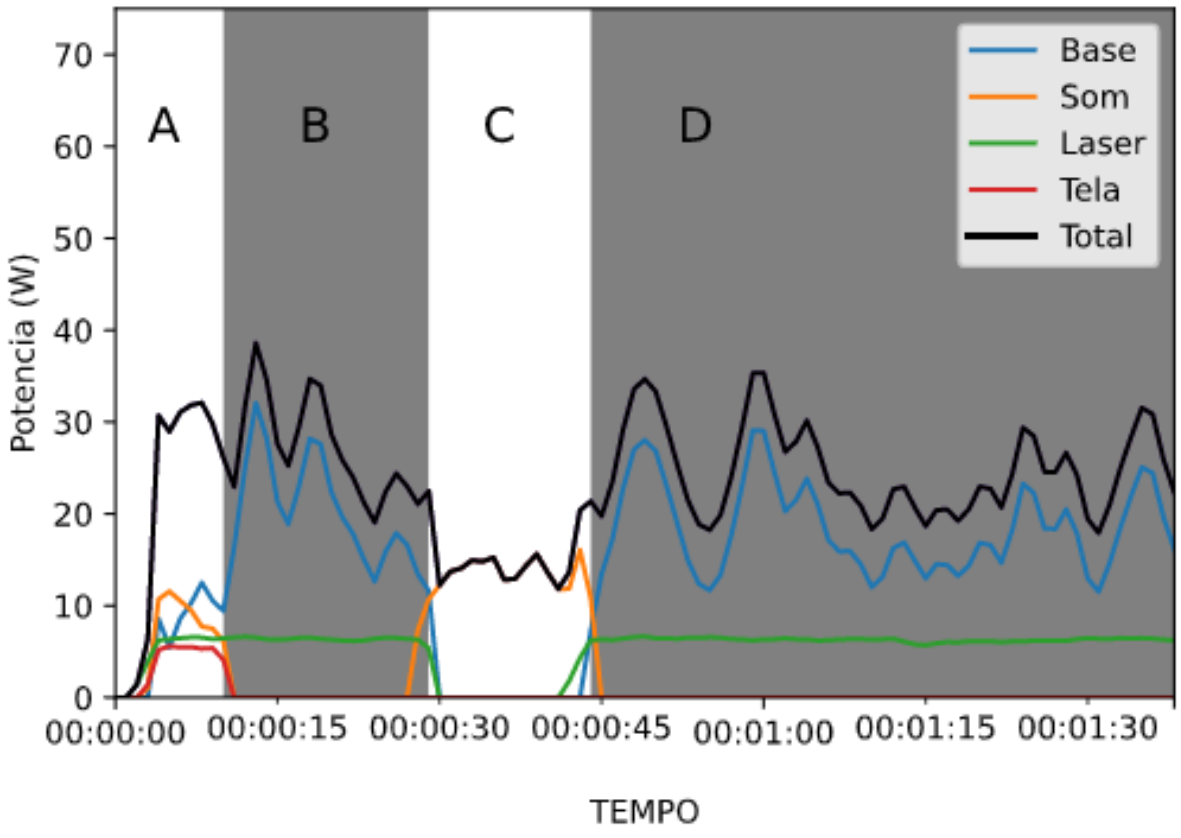

Fonte: Autor

5.3 DISCUSSÃO

Os dados de C_{ps}, T_{Exec} e C_T de cada um dos métodos foram coletados e são apresentados na Figura 32.

Figura 32 – Tabela com métricas de análise

Método	Consumo médio (W/s)	Duração (s)	Consumo Total (W)
Atual	40.494	98	3968.412
Timeout	24.5	102	2499
Preditivo	23	102	2346
Preditivo + pre restart	23.351	98	2288.398
Ideal	23.128	98	2266.544

Fonte: Autor

Ao analisar as métricas, nota-se que o sistema sem nenhum método de gerenciamento tem um C_T 58,8% superior comparado ao método de *timeout*, sendo este o gerenciamento que teve a menor economia de energia.

O método de gerenciamento que possui o menor C_{ps} é o Preditivo, inferior até mesmo ao C_{ps} Ideal. O que faz com que o C_T Preditivo não seja o menor é o T_{Exec}. Tanto o método Preditivo quanto o *Timeout* possuem uma duração superior pois sempre aguardam o chamado, e só então iniciam o processo de transição de estado, o que força o robô a esperar a mudança para dar prosseguimento à execução da tarefa.

O gráfico 7 traz a comparação entre as porcentagens de redução no C_T, quando comparados os métodos com o gasto atual. Do gráfico 7, percebe-se que o método Preditivo com reinicio prévio foi o método cuja economia de energia mais se aproximou à Ideal. Além disso, destaca-se o fato de que mesmo o método de gerenciamento com menor redução de consumo dentre os analisados possui economia de energia superior a 35%, demonstrando o quão energeticamente ineficiente o sistema atual é, e que o DPM pode ser de grande serventia.

Gráfico 7 – Redução do C_T

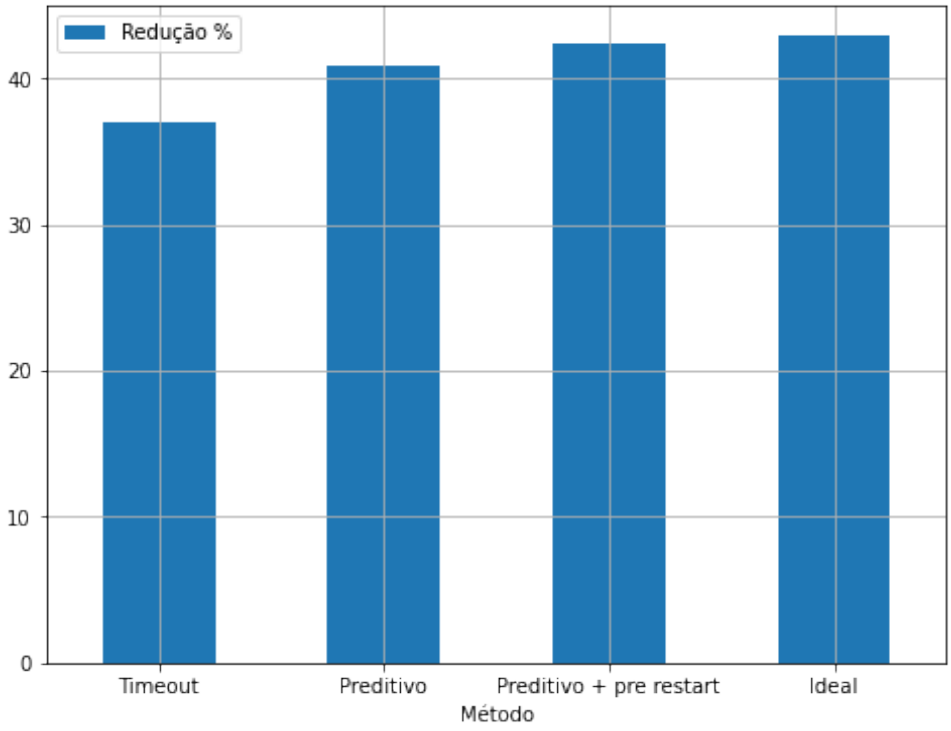

Fonte: Autor

Os resultados da pesquisa trazem uma solução que pode ser aplicada em toda uma gama da robótica móvel, pois como apresentado, a necessidade de mobilidade esta presente em todas as áreas exceto a de robôs estacionários, além de se provar extremamente efetiva em sistemas generalistas como os da robótica móvel de serviço. A presença de diversos sensores e atuadores nestes robôs móveis, que justamente os tornam capazes de realizar as mais diversas tarefas, que não apenas se restringem ao ambiente doméstico, podendo ser facilmente aplicadas em ambientes industriais, hospitalares, sociais, dentre outros.

Além disso o sistema de captação de dados desenvolvido nesta pesquisa pode ser facilmente adaptado em qualquer sistema robótico, facilitando não só a aquisição e analise de dados em diversos sistemas e ambientes, mas também a análise individual de módulos sob condições de operações.

Com os dados coletados durante essa pesquisa, uma base inicial de conhecimento do funcionamento de módulos de um sistema robótico móvel foi gerada, a qual pode ser utilizada em futuras pesquisas na área de eficiência energética em robôs móveis. Informações sobre acesso à base estão presentes no Apêndice A.

6 CONCLUSÕES

Este trabalho propõe a modelagem de um sistema de Gerenciamento Dinâmico de Energia em robôs móveis, com objetivo de aumentar o tempo de funcionamento, desenvolver um sistema de captação de dados para futuras tomadas de decisões relacionadas ao sistema de energia e a realização de tarefas, e criar uma base de conhecimento do funcionamento de sensores e atuadores em robôs móveis de plataforma aberta.

As pesquisas presentes nos trabalhos relacionados demonstram a eficácia do DPM na redução do consumo energético em diversos ramos. Corroboram também os artigos de alta relevância, que comprovam possibilidade da aplicação do gerenciamento em robôs móveis. Ademais, como demonstrado no mapeamento do sistema realizado, o robô HERA possui caraterísticas como a necessidade de mobilidade, assim como uma gama de sensores e atuadores para cumprir as mais determinadas funções. Essas características fazem com que o sistema se beneficie do DPM, pois a necessidade de alta mobilidade limita as opções de fonte de energia, fazendo com que a bateria seja escolhida, e a presença de diversos sensores e atuadores, apesar de garantir a realização das mais diversas tarefas, faz com que, por diversos momentos, eles gastem energia sem serem utilizados.

Após análises dos dados, constata-se a falta de métodos de economia de energia presentes no robô, com um consumo 77,06% superior ao consumo ideal. Neste trabalho foram simulados os consumos energéticos ao se realizar tarefas utilizando os métodos de *timeout* com 2 segundos, preditivo, e preditivo com reinicio antecipado. Os resultados dos testes trazem o método de DPM preditivo com reinicio antecipado como o que melhor se aproxima do sistema ideal, em seguida o método preditivo aparece, seguido pelo *timeout*, que foi o que apresentou a menor % de redução, com 37% de economia. Nota-se também que mesmo o método com pior resultado apresenta uma redução considerável no consumo, mostrando a alta aplicabilidade de DPM em robôs móveis.

O sistema de aquisição e armazenamento de dados desenvolvido para a criação da base de conhecimento se mostrou confiável, produzindo resultados condizentes com a realidade, de implementação simples, e adequado para as necessidades de coleta de dados em robôs móveis.

A base de conhecimento gerada nesta pesquisa inicia uma coleção de dados de funcionamento de módulos de um robô móvel sob diferentes módulos de operação, o que pode vir a ser utilizado em pesquisas futuras na área de gerenciamento de energia.

Como trabalhos futuros, o estudo para a integração de módulos com sistema de comunicação e alimentação proprietários deve ser estudada, para possibilitar a aplicação do DPM em mais módulos do sistema, o que acarretaria em mais economia de energia.

APÊNDICE A – BASE DE CONHECIMENTO

Os dados coletados nesta pesquisa e que compõem a base de conhecimento gerada neste trabalho podem ser acessados em https://github.com/rtechi/base_de_conhecimento.

REFERÊNCIAS

AAGELA, H; AL-JODY, T; HOLMES, V. Web-based Wireless Wake-on-LAN approach for Robots. In: 2018 24th International Conference on Automation and Computing (ICAC). [S.l.: s.n.], 2018. p. 1–5.

ALLEGRO MICROSYSTEMS. **Fully Integrated, Hall Effect-Based Linear Current Sensor with 2.1 kVRMS Voltage Isolation and a Low-Resistance Current Conductor**. [S.l.], jan. 2006.

BABU, D; KUMAR, A; ROYCHOWDHURY, J. FPGA based model predictive controller for dynamic power management of a battery powered electric car. In: 2012 12th International Conference on Intelligent Systems Design and Applications (ISDA). [S.l.: s.n.], 2012. p. 363–368. DOI: 10.1109/ISDA.2012.6416565.

BAKKER, Tijmen et al. Autonomous navigation using a robot platform in a sugar beet field. **Biosystems Engineering**, Elsevier, v. 109, n. 4, p. 357–368, 2011.

BENINI, Luca; BOGLIOLO, Alessandro; DE MICHELI, Giovanni. A survey of design techniques for system-level dynamic power management. **IEEE transactions on very large scale integration (VLSI) systems**, IEEE, v. 8, n. 3, p. 299–316, 2000.

BENINI, Luca; BOGLIOLO, Alessandro; DE MICHELI, Giovanni. Dynamic power management of electronic systems. In: PROCEEDINGS of the 1998 IEEE/ACM international conference on Computer-aided design. [S.l.: s.n.], 1998. p. 696–702.

BENINI, Luca; MICHELI, Giovanni de. **Dynamic Power Management: Design Techniques and CAD Tools**. Norwell, MA, USA: Kluwer Academic Publishers, 1997. ISBN 079238086X.

BENINI, Luca et al. Policy optimization for dynamic power management. **IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems**, IEEE, v. 18, n. 6, p. 813–833, 1999.

BIN WANG et al. Power-aware real-time task scheduling with feedback control for mobile robots. In: 2008 3rd IEEE Conference on Industrial Electronics and Applications. [S.l.: s.n.], 2008. p. 1240–1245.

BOXERBAUM, AS; CHIEL, HJ; QUINN, RD. Softworm: A soft, biologically inspired worm-like robot. In: 5817. NEUROSCIENCE Abstracts. [S.l.: s.n.], 2009. v. 315, p. 44106.

BRAND, Peter et al. Adaptive Predictive Power Management for Mobile LTE Devices. **IEEE Transactions on Mobile Computing**, IEEE, 2020.

CHEN, Hung-Ming et al. Designing platform-based system power management on a smart tablet appliance. In: IEEE. 10TH IEEE International Conference on Electronics, Circuits and Systems, 2003. ICECS 2003. Proceedings of the 2003. [S.l.: s.n.], 2003. v. 1, p. 316–319.

CHENG, S; HUANG, I. Real-time dynamic power management of electrically assisted bicycle. In: 2011 IEEE International Conference on Mechatronics and Automation. [S.l.: s.n.], 2011. p. 313–318. DOI: 10.1109/ICMA.2011.5985676.

CHUNG, Eui-Young et al. Dynamic power management for nonstationary service requests. **IEEE Transactions on Computers**, IEEE, v. 51, n. 11, p. 1345–1361, 2002.

COUSINEAU, Jefrrey; LE, Huynh-Anh; AL, et. **Walking Machine @Home 2019 Team Description Paper**. 2019.

CRUZ, N A; MATOS, A C. The MARES AUV, a Modular Autonomous Robot for Environment Sampling. In: OCEANS 2008. [S.l.: s.n.], 2008. p. 1–6.

DHIMAN, Gaurav; ROSING, Tajana Simunic. Dynamic power management using machine learning. In: ACM. PROCEEDINGS of the 2006 IEEE/ACM international conference on Computer-aided design. [S.l.: s.n.], 2006. p. 747–754.

DURMUS, H et al. The design of general purpose autonomous agricultural mobile-robot: fffdAGROBOTfffd. In: 2015 Fourth International Conference on Agro-Geoinformatics (Agro-geoinformatics). [S.l.: s.n.], 2015. p. 49–53.

FLOCCHINI, P; OMAR, E; SANTORO, N. Effective Decentralized Energy Restoration by a Mobile Robot. In: 2019 Seventh International Symposium on Computing and Networking (CANDAR). [S.l.: s.n.], 2019. p. 73–81.

GARY, Sonya et al. The PowerPC 603 microprocessor: a low-power design for portable applications. In: IEEE. PROCEEDINGS of COMPCON'94. [S.l.: s.n.], 1994. p. 307–315.

GIUSEPPE MARCO, T et al. Design considerations about a photovoltaic power system to supply a mobile robot. In: 2010 IEEE International Symposium on Industrial Electronics. [S.l.: s.n.], 2010. p. 1829–1834.

GUO, Qianying et al. Research on Reinforcement Learning-Based Dynamic Power Management for Edge Data Center. In: IEEE. 2018 IEEE 9th International Conference on Software Engineering and Service Science (ICSESS). [S.l.: s.n.], 2018. p. 865–868.

HENKEL, Christian; BUBECK, Alexander; XU, Weiliang. Energy efficient dynamic window approach for local path planning in mobile service robotics. **IFAC-PapersOnLine**, Elsevier, v. 49, n. 15, p. 32–37, 2016.

HO, D et al. Towards a Multi-mission QoS and Energy Manager for Autonomous Mobile Robots. In: 2018 Second IEEE International Conference on Robotic Computing (IRC). [S.l.: s.n.], 2018. p. 270–273.

HSU, R C et al. A Reinforcement Learning Based Dynamic Power Management for Fuel Cell Hybrid Electric Vehicle. In: 2016 Joint 8th International Conference on Soft Computing and Intelligent Systems (SCIS) and 17th International Symposium on Advanced Intelligent Systems (ISIS). [S.l.: s.n.], 2016. p. 460–464. DOI: 10.1109/SCIS-ISIS.2016.0104.

HUANG, Chong. **Towards a Smart Drone Cinematographer for Filming Human Motion**. 2020. Tese (Doutorado) – UC Santa Barbara.

HUNG-MING CHEN et al. Designing platform-based system power management on a smart tablet appliance. In: 10TH IEEE International Conference on Electronics, Circuits and Systems, 2003. ICECS 2003. Proceedings of the 2003. [S.l.: s.n.], 2003. v. 1, 316–319 vol.1. DOI: 10.1109/ICECS.2003.1302040.

HUO, Jianghao et al. **Tinker@Home 2019 Team Description Paper**. 2019.

HWANG, Chi-Hong; WU, Allen C-H. A predictive system shutdown method for energy saving of event-driven computation. **ACM Transactions on Design Automation of Electronic Systems (TODAES)**, ACM New York, NY, USA, v. 5, n. 2, p. 226–241, 2000.

HWANG, Young-Si; KU, Sung-Kwan; CHUNG, Ki-Seok. A predictive dynamic power management technique for embedded mobile devices. **IEEE Transactions on Consumer Electronics**, IEEE, v. 56, n. 2, p. 713–719, 2010.

ISSA, Ahmed et al. Vision Assisted SCARA Manipulator Design and Control Using Arduino and LabVIEW. In: IEEE. 2017 International Conference on Promising Electronic Technologies (ICPET). [S.l.: s.n.], 2017. p. 54–59.

JIANG, Q; XI, H-S; YIN, B-Q. Adaptive optimisation of timeout policy for dynamic power management based on semi-Markov control processes. **IET control theory & applications**, IET, v. 4, n. 10, p. 1945–1958, 2010.

KAMAMICHI, Norihiro et al. A snake-like swimming robot using IPMC actuator/sensor. In: IEEE. PROCEEDINGS 2006 IEEE International Conference on Robotics and Automation, 2006. ICRA 2006. [S.l.: s.n.], 2006. p. 1812–1817.

KERAMIDAS, G. et al. Optimizing the Operational Time of Ambient Assisting Living Robots. **IEEE Consumer Electronics Magazine**, v. 9, n. 3, p. 97–104, 2020.

KHATIB, Oussama et al. Ocean one: A robotic avatar for oceanic discovery. **IEEE Robotics & Automation Magazine**, IEEE, v. 23, n. 4, p. 20–29, 2016.

KITCHENHAM, Barbara. Procedures for performing systematic reviews. **Keele, UK, Keele University**, v. 33, n. 2004, p. 1–26, 2004.

KONG, F et al. Genetic Algorithm Based Idle Length Prediction Scheme for Dynamic Power Management. In: THE Proceedings of the Multiconference on "Computational Engineering in Systems Applications". [S.l.: s.n.], 2006. v. 2, p. 1437–1443. DOI: 10.1109/CESA.2006.4281864.

KONG, F et al. Genetic Algorithm Based Idle Length Prediction Scheme for Dynamic Power Management. In: THE Proceedings of the Multiconference on "Computational Engineering in Systems Applications". [S.l.: s.n.], 2006. v. 2, p. 1437–1443. DOI: 10.1109/CESA.2006.4281864.

LUN XIE; QINGYI QIAO; ZHILIANG WANG. An efficient power management system for biped robot. In: 2008 International Conference on Electrical Machines and Systems. [S.l.: s.n.], 2008. p. 2130–2135.

LUO, Ming et al. Micro-/nanorobots at work in active drug delivery. **Advanced Functional Materials**, Wiley Online Library, v. 28, n. 25, p. 1706100, 2018.

MARCU, Marius; TUDOR, Dacian. Execution framework model for power-aware applications. In: IEEE. 2011 17th International Workshop on Thermal Investigations of ICs and Systems (THERMINIC). [S.l.: s.n.], 2011. p. 1–6.

MARTIN, Steven et al. **Australian Center for Robotic Vision RoboCup@Home Team Description Paper**. 2019.

MATAMOROS, Mauricio et al. **RoboCup@Home 2019: Rules and Regulations (draft)**. [S.l.: s.n.], 2019. http://www.robocupathome.org/rules/2019_rulebook.pdf.

MATHEWS, T; GOPI, V. Embedded system based power management for battery operating robotic vehicle. In: 2014 International Conference on Circuits, Power and Computing Technologies [ICCPCT-2014]. [S.l.: s.n.], 2014. p. 503–508.

MEI, Yongguo; LU, Yung-Hsiang; HU, Y Charlie. A case study of mobile robot's energy consumption and conservation techniques. In: IEEE. ICAR'05. Proceedings., 12th International Conference on Advanced Robotics, 2005. [S.l.: s.n.], 2005. p. 492–497.

MEMMESHEIMER, Raphael et al. **RoboCup 2019 - homer@UniKoblenz (Germany)**. 2019.

MITCHELL, Tom M et al. **Machine learning**. [S.l.]: McGraw-hill New York, 1997.

MOHRI, Mehryar; ROSTAMIZADEH, Afshin; TALWALKAR, Ameet. **Foundations of machine learning**. [S.l.]: MIT press, 2018.

MOORE, Gordon E et al. **Cramming more components onto integrated circuits**. [S.l.]: McGraw-Hill New York, NY, USA: 1965.

MUFFOLETTO, D P et al. Design and analysis of a smart power management system for ultracapacitor-powered robotic platform. In: 2010 IEEE International Power Modulator and High Voltage Conference. [S.l.: s.n.], 2010. p. 643–646.

NAVEAU, M et al. MARIUS project: Design of a sail robot for oceanographic missions. In: 2013 OCEANS - San Diego. [S.l.: s.n.], 2013. p. 1–6.

NDJOUNTCHE, Tertulien. **Digital Electronics 3: Finite-state Machines**. [S.l.]: John Wiley & Sons, 2016.

OKAMURA, Hiroyuki; DOHI, Tadashi. Dynamic power management with optimal time-out policies. **IEEE Systems Journal**, IEEE, v. 11, n. 2, p. 962–972, 2015.

ORTIGOZA, Ramon Silva et al. Wheeled mobile robots: a review. **IEEE Latin America Transactions**, IEEE, v. 10, n. 6, p. 2209–2217, 2012.

PAN, S. et al. A low-power SoC-based moving target detection system for amphibious spherical robots. In: 2015 IEEE International Conference on Mechatronics and Automation (ICMA). [S.l.: s.n.], 2015. p. 1116–1121.

PERRUCCI, Gian Paolo; FITZEK, Frank HP; WIDMER, Jörg. Survey on energy consumption entities on the smartphone platform. In: IEEE. 2011 IEEE 73rd vehicular technology conference (VTC Spring). [S.l.: s.n.], 2011. p. 1–6.

PRATT, Leslie. **MQ-1 Predator on patrol**. Ago. 2020. Disponível em: <https://www.afrc.af.mil/News/Photos/igphoto/2000608212/>.

RAIBERT, Marc et al. Bigdog, the rough-terrain quadruped robot. **IFAC Proceedings Volumes**, Elsevier, v. 41, n. 2, p. 10822–10825, 2008.

RATSCH, Matthias et al. **RT Lions Team Description Pape**. 2019.

REN, Z; KROGH, B H; MARCULESCU, R. Hierarchical adaptive dynamic power management. **IEEE Transactions on Computers**, v. 54, n. 4, p. 409–420, 2005. ISSN 2326-3814. DOI: 10.1109/TC.2005.66.

REN, Zhiyuan; KROGH, Bruce H; MARCULESCU, Radu. Hierarchical adaptive dynamic power management. **IEEE Transactions on Computers**, IEEE, v. 54, n. 4, p. 409–420, 2005.

RUBIO, Francisco; VALERO, Francisco; LLOPIS-ALBERT, Carlos. A review of mobile robots: Concepts, methods, theoretical framework, and applications. **International Journal of Advanced Robotic Systems**, SAGE Publications Sage UK: London, England, v. 16, n. 2, p. 1729881419839596, 2019.

SAUZÉ, C.; NEAL, M. Artificial Endocrine Controller for Power Management in Robotic Systems. **IEEE Transactions on Neural Networks and Learning Systems**, v. 24, n. 12, p. 1973–1985, 2013.

SAVAGE, Jesus et al. **Pumas@Home 2019 Team Description Paper**. 2019.

SHARMA, R K; MISHRA, S. Dynamic Power Management and Control of a PV PEM Fuel-Cell-Based Standalone ac/dc Microgrid Using Hybrid Energy Storage. **IEEE Transactions on Industry Applications**, v. 54, n. 1, p. 526–538, 2018. ISSN 1939-9367. DOI: 10.1109/TIA.2017.2756032.

SHINTAKE, Jun et al. Bio-inspired Tensegrity Fish Robot. In: IEEE. 2020 IEEE International Conference on Robotics and Automation (ICRA). [S.l.: s.n.], 2020. p. 2887–2892.

SICILIANO, Bruno; KHATIB, Oussama. **Springer handbook of robotics**. [S.l.]: Springer, 2016.

SILVA, Manuel Fernando; MACHADO, JA Tenreiro. A literature review on the optimization of legged robots. **Journal of Vibration and Control**, Sage Publications Sage UK: London, England, v. 18, n. 12, p. 1753–1767, 2012.

SIMUNIC, Tajana et al. Dynamic power management of laptop hard disk. In: IEEE. PROCEEDINGS Design, Automation and Test in Europe Conference and Exhibition 2000 (Cat. No. PR00537). [S.l.: s.n.], 2000. p. 736.

SPRINGER, Paul J. **Military robots and drones: a reference handbook**. [S.l.]: ABC-CLIO, 2013.

SRIVASTAVA, Mani B; CHANDRAKASAN, Anantha P; BRODERSEN, Robert W. Predictive system shutdown and other architectural techniques for energy efficient programmable computation. **IEEE Transactions on Very Large Scale Integration (VLSI) Systems**, IEEE, v. 4, n. 1, p. 42–55, 1996.

SUN, Tao et al. A transformable wheel-legged mobile robot: design, analysis and experiment. **Robotics and Autonomous Systems**, Elsevier, v. 98, p. 30–41, 2017.

TAN, Jeffrey Too Chuan. **KameRider OPL @Home 2019 Team Description Paper**. 2019.

TECHI, Rodrigo C. et al. RoboFEI@Home Team Description Paper for RoboCup@Home 2020. [S.l.], 2020.

TOMY, M et al. Battery Charge Scheduling in Long-Life Autonomous Mobile Robots. In: 2019 European Conference on Mobile Robots (ECMR). [S.l.: s.n.], 2019. p. 1–6.

TRIKI, M et al. Reinforcement Learning-Based Dynamic Power Management of a Battery-Powered System Supplying Multiple Active Modes. In: 2013 European Modelling Symposium. [S.l.: s.n.], 2013. p. 437–442. DOI: 10.1109/EMS.2013.74.

WANG, C; HUANG, W; CHIU, J. Intelligent power management of Lithium-ferro-phosphate cells on the homecare robot. In: 2009 IEEE/ASME International Conference on Advanced Intelligent Mechatronics. [S.l.: s.n.], 2009. p. 1527–1532.

WANG, Yanzhi et al. Deriving a near-optimal power management policy using model-free reinforcement learning and Bayesian classification. In: PROCEEDINGS of the 48th Design Automation Conference. [S.l.: s.n.], 2011. p. 41–46.

WEI, Hongxing et al. Staying-alive path planning with energy optimization for mobile robots. **Expert Systems with Applications**, v. 39, n. 3, p. 3559–3571, 2012. ISSN 0957-4174. DOI: https://doi.org/10.1016/j.eswa.2011.09.046. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0957417411013558>.

YANG, Guang-Zhong et al. The grand challenges of Science Robotics. **Science robotics**, Science Robotics, v. 3, n. 14, eaar7650, 2018.

YUE, S. et al. Reinforcement learning based dynamic power management with a hybrid power supply. In: 2012 IEEE 30th International Conference on Computer Design (ICCD). [S.l.: s.n.], 2012. p. 81–86. DOI: 10.1109/ICCD.2012.6378621.

ZHANG, Wei; HU, Jianghai. Low power management for autonomous mobile robots using optimal control. In: IEEE. 2007 46th IEEE Conference on Decision and Control. [S.l.: s.n.], 2007. p. 5364–5369.