

**UNIVERSIDADE FEDERAL DE SÃO CARLOS - UFSCAR
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA - CCET
DEPARTAMENTO DE ENGENHARIA MECÂNICA - DEMec**

GABRIELA TAVARES MASCOLOTI

**Desenvolvimento e aplicação de módulo de sensoriamento de baixo custo
para o monitoramento de saúde estrutural de máquina rotativa**



São Carlos - SP
2021

GABRIELA TAVARES MASCOLOTI

**Desenvolvimento e aplicação de módulo de sensoriamento de baixo custo
para o monitoramento de saúde estrutural de máquina rotativa**

Trabalho de conclusão de curso apresentado ao curso de graduação em Engenharia Mecânica da Universidade Federal de São Carlos, para obtenção do título de bacharel em Engenharia Mecânica.

Orientador: Prof. Dr. Sidney Bruce Shiki

São Carlos - SP
2021

Folha de Aprovação

Resultado da avaliação da defesa pública do Trabalho de Conclusão de Curso do discente **Gabriela Tavares Mascoloti**, intitulado "**Desenvolvimento e aplicação de módulo de sensoriamento de baixo custo para o monitoramento de saúde estrutural de máquina rotativa**", defendido junto ao curso de Engenharia Mecânica da Universidade Federal de São Carlos na presente data.

Resultado:

Prof. Dr. Sidney Bruce Shiki (orientador)

DEMec/UFSCar

Prof. Dr. Mariano Eduardo Moreno

DEMec/UFSCar

Eng. Anderson da Costa Kramer

Automação/ Ambev

São Carlos, 22 de outubro de 2021

Dedico este trabalho à minha família, amigos e professores que estiveram ao meu lado durante toda essa jornada.

Agradecimentos

Primeiramente gostaria de agradecer aos meus pais e irmã: Valéria, Silvio e Bruna por terem me acompanhado desde o início da vida e me incentivado a sempre buscar meus sonhos. Minha inspiração, fortaleza e porto seguro. Sem eles nada disso teria sido possível.

Agradeço também ao meu tio Cláudio, meu conselheiro e amigo para todas as horas, me inspira, orienta e está sempre comigo. Meus avós, Cida, Wilson, Dirce e José que foram fundamentais na minha criação e são minha família para sempre.

Agradeço ao meu professor Orientador Bruce, que me apoiou durante toda a minha jornada da graduação, iniciação científica e trabalho de conclusão de curso. Seus ensinamentos, paciência e instrução foram fundamentais na minha formação. Ainda agradeço a todo o corpo docente da UFSCar e especialmente aos meus professores do DEMEC, os quais foram ativos e essenciais na minha formação como engenheira mecânica.

Essa jornada, com certeza, não teria sido nada fácil e nem divertida sem meus amigos da turma: Camila, Gabi, Amanda, Pelé, Ed, Albano, Cleber, Napo, Caju, Ygor, Sid e muitos outros que estão no meu coração. Tenho certeza que tudo o que vivemos juntos nesses 6 anos vai ficar marcado em nossas vidas e saio daqui com a certeza de que tenho verdadeiros irmãos.

Antes de pensar em qualquer curso de graduação minhas amigas irmãs de vida sempre estiveram ao meu lado: Maria e Luiza, sem vocês nada disso teria graça, vocês são minha base e família. Aos amigos que fiz durante meu estágio e me ajudaram a completar essa jornada enquanto vivia meu sonho também devo agradecimentos: Carol, Karina, Dutra, Kramer e todo o time que me ajudou a colocar meu trabalho em prática!

Agradeço a Deus sempre por ter me concedido sabedoria e força na jornada de realizar o sonho de cursar uma universidade federal, fazer estágio na empresa que almejei e terminar a graduação empregada em meio a tantos desafios.

*"Faça o teu melhor, na condição que
você tem, enquanto voce não
tem condições melhores
para fazer melhor ainda."*

Mario Sergio Cortela

Resumo

Manutenção preditiva é um modelo recente de manutenção no mercado, embora já bem conhecido na indústria aeronáutica, e se faz cada vez mais necessário em qualquer ambiente fabril. O projeto de pesquisa tem como objetivo o desenvolvimento de nós de medição de baixo custo para monitoramento preditivo da saúde de máquinas visando aumento de performance da produção com diminuição de custos de manutenção a longo prazo. Integrado ao conceito de internet das coisas (Internet of Things -IoT) e processamento de dados, resultará em uma ferramenta de aumento de confiabilidade de máquinas. Justamente por se tratar de um desenvolvimento de baixo custo, que será desenvolvido em laboratório com hardware e sensor comerciais, os principais desafios do projeto é o dimensionamento de tal forma que satisfaça os requisitos de um ambiente industrial e sejam vantajosos economicamente. Além disso, uma vez desenvolvido o corpo técnico responsável pelo monitoramento deve ser treinado para a correta leitura das informações que serão tratadas e fornecidas a partir de uma plataforma de comunicação com nuvem. Outro desafio da pesquisa é conseguir instalar o protótipo desenvolvido em uma fábrica e comprovar a eficiência do método. O principal foco da pesquisa é desenvolver um dispositivo de monitoramento preditivo de fácil instalação e funcionamento com baixo custo integrado com tratamento de dados via nuvem e de possível aplicação para indústria. Uma vez atingido esse objetivo, o dispositivo será testado em laboratório e em ambiente industrial para a validação do estudo e comparação de dados. O estudo será centrado na comparação de performance de máquinas com e sem monitoramento via o dispositivo desenvolvido na pesquisa, para assim provar a importância e necessidade da manutenção preditiva alinhada com tratamento de dados na indústria.

Palavras-chave: Preditiva, IOT, manutenção, *MEMS*.

Abstract

Predictive maintenance is a recent maintenance model on the market, although it is already well known in the aeronautical industry, and it is increasingly necessary in any manufacturing environment. The research project aims to develop low-cost reduction nodes for predictive monitoring of machine health, increasing production performance and reducing long-term maintenance costs. Integrated with the concept of Internet of Things (IoT) and data processing, it will result in a tool to increase machine reliability. Precisely because it is a low-cost development, which will be developed in a laboratory with hardware and commercial sensor, the main challenges of the project is the dimensioning in such a way that it meets the requirements of an industrial environment and is economically advantageous. In addition, once developed, the technical staff responsible for monitoring must be trained to correctly read the information that will be treated and provided from a communication platform with the cloud. Another challenge of the research is to be able to install the prototype developed in a factory and prove the efficiency of the method. The focus of the main research is to develop a predictive monitoring device that is easy to install and operate with low cost, integrated with data treatment via the cloud and possible Application for industry. Once this goal is achieved, the device will be tested in a laboratory and industrial environment for study validation and data comparison. The study will focus on comparing the performance of machines with and without monitoring via a device developed in the research, in order to prove the importance and necessity of predictive maintenance aligned with data processing in the industry.

Keywords: Predictive, IOT, maintenance, MEMS.

Lista de Figuras

1	Modelo Vibratório	23
2	Relação entre Deslocamento, Velocidade e Aceleração de um movimento senoidal oscilatório	25
3	Fluxograma do sistema de Medição Implementado	31
4	Ligação Raspberry e MPU-6050	33
5	Interface ThingSpeak™	34
6	Motor de estudo	35
7	Sensor Band Trac	36
8	Sistema de Medição Desenvolvido	37
9	Sistema de Medição Desenvolvido no Motor em estudo	37
10	Fixação Sensor MPU6050 no motor em estudo	38
11	Evolução das configurações experimentais	39
12	Velocidade RMS em X	42
13	Velocidade RMS em X nó de sensoriamento	43
14	Velocidade RMS em Y	44
15	Aceleração RMS em Y nó de sensoriamento	44
16	Velocidade RMS em Z	45
17	Aceleração RMS em Z nó de sensoriamento	46
18	Temperatura	46
19	Temperatura nó de sensoriamento	47

Lista de Tabelas

1	Faixas de severidade de vibração segundo NBR 10082	28
2	Classes de operação segundo NBR 10082	29
3	Classificação das máquinas por nível de severidade segundo NBR 10082	29
4	Especificações MPU 6050	31
5	Especificações Raspberry Pi 4	32
6	Especificações Motor de Estudo	35
7	Especificações BandTrac	36
8	Classificação de nível de operação do motor medido pelo eixo x	42
9	Classificação de nível de operação do motor medido pelo eixo y	44
10	Classificação de nível de operação do motor medido pelo eixo z	45

Lista de Siglas

SHM	-	structural health monitoring
AD	-	analógico-digital
IoT	-	Internet of Things
MIT	-	Massachusetts Institute of Technology
ITU	-	União Internacional de Tele-comunicações
MEMS	-	Micro-Electro-Mechanical Systems
FPGA	-	Field Programmable Gate Array
WSN	-	Wireless sensor networks
RMS	-	Root Mean Square

Lista de Símbolos

- t - parâmetro da função de tempo para descrição de sinal de vibração $x(t)$
- ω - velocidade angular e parâmetro da função de seno para descrição de sinal de vibração $x(t)$
- ϕ - arcseno da amplitude inicial pela amplitude do sinal de vibração representado por $x(t)$
- f - frequência calculada a partir do período do sinal de vibração $x(t)$
- X - Amplitude do sinal de vibração
- X_0 - Amplitude inicial do sinal de vibração
- $v(t)$ - derivada da função $x(t)$ e velocidade da vibração
- $a(t)$ - derivada da função $v(t)$ e aceleração da vibração
- x_{RMS} - valor eficaz de deslocamento
- N - Número de amostras do sinal
- $x(n)$ - Sinal de vibração medido

Sumário

1	Introdução	13
1.1	Objetivos	15
1.1.1	Objetivos Específicos	15
2	Revisão bibliográfica	16
2.1	Vibrações mecânicas	16
2.2	Manutenção preditiva	17
2.3	Sensores e Hardware de baixo custo	20
2.4	Considerações a respeito da leitura	22
3	Fundamentação teórica	23
3.1	Fundamentos de vibrações mecânicas	23
3.2	Manutenção preditiva baseada em análise de vibrações	26
4	Materiais e métodos	30
4.1	Descrição do sistema de medição implementado	30
4.2	Descrição do setup experimental	34
4.3	Metodologia dos experimentos realizados	38
5	Análise dos resultados	41
5.1	Resultados Teste em Campo	41
6	Conclusões	48
	Referências	50
	Apêndice A - Código Python	54

1 Introdução

A sociedade moderna é altamente dependente de estruturas e máquinas tais como pontes, aviões, máquinas rotativas, plataformas *offshore*, entre outros (FARRAR; WORDEN, 2012). Todos esses sistemas podem ter alta importância econômica e a manutenção de sua integridade estrutural é também importante para a segurança de vidas humanas e do próprio meio ambiente (INMAN et al., 2005a).

Exemplos clássicos neste assunto estão na indústria aeronáutica no caso da separação da fuselagem de um Boeing 737 da *Aloha Airlines* devido à trincas por fadiga (SOHN et al., 2004) e em estruturas civis como uma ponte que desabou na cidade de Minneapolis nos Estados Unidos (Popular Mechanics, 2007). Eventos catastróficos como estes evidenciam a necessidade de se ter um pleno controle da integridade estrutural desses sistemas.

Nesse sentido, a identificação de danos em sistemas mecânicos, civis e aeronáuticos é um passo crucial para se poder intervir na operação de um sistema de modo a realizar manutenções programadas ou em casos mais drásticos na interrupção da atividade dessas estruturas (ADAMS, 2007). O monitoramento da saúde estrutural (*SHM* do inglês *structural health monitoring*) é uma área de pesquisa preocupada com a implementação de métodos para identificação de danos para sistemas aeroespaciais, civis e mecânicos. Técnicas de *SHM*, em geral compreendem a detecção, localização, estabelecimento do tipo de dano, quantificação do mesmo e prognóstico da vida útil restante dessas estruturas.

Diversas técnicas para monitoramento estrutural baseadas em medições de vibrações mecânicas têm sido desenvolvidas na literatura para o monitoramento de estruturas civis (BANDARA R. P.; CHAN, 2014), ou em máquinas rotativas (HAMEED et al., 2009), onde este tópico já possui larga aplicação industrial. Estes estudos têm mostrado um enorme ganho potencial de disponibilidade dos equipamentos bem como na economia de recursos que seriam destinados à manutenção frequente desses sistemas (INMAN et al., 2005b). No entanto, a instrumentação envolvida no processo de

detecção de danos em geral é de elevado custo visto que envolve sensores e placas de conversão analógico-digital (AD) entre outros componentes de instrumentação de estruturas que muitas vezes tem de ser importados no caso de países como o Brasil.

Um fator recente de extrema relevância na área tecnológica está na popularização de conceitos como *hardware* livre, computadores de placa única de baixo custo, e sobretudo do conceito de integração desses elementos pela chamada 'internet das coisas' ou *IoT- Internet of Things* em inglês (ASHTON et al., 2009). Segundo Atzori et al. (2010) isto traz um potencial enorme de aplicações para transporte, saúde e automação residencial. Um relatório em um evento promovido em 2008 pelo *National Intelligence Council* do governo dos Estados Unidos apontou esse novo conceito como uma das 6 tecnologias com maior potencial de impacto nos interesses desse país até 2025 (*National Intelligence Council, 2008*). Os elaboradores desse trabalho enxergavam um futuro não tão distante onde todo objeto cotidiano, aparelhos, construções e máquinas são altamente integradas e instrumentadas, além de interagirem entre si e com os usuários por meio da internet que se faz cada vez mais presente atualmente por conta do avanço tecnológico.

Outro fator importante são novos elementos de *hardware* abertos, cujo projeto é distribuído livremente para a comunidade científica modificar e incrementar, tem contribuído para o conceito de *IoT* e também para a construção de equipamentos para uso científico em laboratórios de pesquisa (GIBNEY, 2016). Alguns trabalhos têm sido desenvolvidos com o intuito de explorar essas novas tecnologias para aplicações da engenharia. (CHEN et al., 2009) desenvolveram um dispositivo sem fio para transmissão de dados de uma unidade de tratamento intensivo neonatal. A ideia do projeto foi desenvolver uma instrumentação menos invasiva e incômoda permitindo a interação dos pais com os recém nascidos. Ferdoush e Li (2014) desenvolveram um sistema para monitoramento de variáveis ambientais, como temperatura e umidade, baseados em uma placa Raspberry Pi e Arduino. O sistema foi utilizado para amostrar esses sinais dentro de um prédio. O sistema foi projetado para registrar esses dados e enviá-los para uma interface web de modo que outros usuários pudessem acessá-los. Andò et al. (2014) utilizaram uma placa Arduino Uno, juntamente com acelerômetros e inclinômetros para criar um nó de sensoramento para aplicações em prédios e estruturas civis. O desenvolvimento do hardware foi pensado para integrar um rede sem fio de sensores que se comunicam com uma central para onde a informação é enviada.

Embora existam algumas aplicações recentes para monitoramento de sistemas de engenharia como demonstrado anteriormente, a utilização de *hardware* livre e de

baixo custo para monitoramento de estruturas e máquinas é ainda pouco explorada. O advento de sensores, transmissores sem fio, bem como processadores mais acessíveis, principalmente impulsionado pela tecnologia de dispositivos móveis é um fator importante. Além do baixo custo, outra grande vantagem das tecnologias abertas é a grande quantidade de informações livremente disponibilizada na internet para resolução de problemas técnicos envolvendo esses dispositivos. Nesse sentido, este projeto de pesquisa se concentrará nos esforços de verificar a viabilidade técnica da aplicação de hardware de baixo custo em aplicações para monitoramento de estruturas de máquinas.

1.1 Objetivos

Desenvolver um módulo para monitoramento de máquinas para aplicações com medições de temperatura e aceleração baseado em hardware de baixo custo comparando o mesmo com sistema de monitoramento industrial.

1.1.1 Objetivos Específicos

- Estudar na literatura diferentes aplicações de hardware de baixo custo e de arquitetura aberta para monitoramento de estruturas e máquinas;
- Investigar o funcionamento desse tipo de hardware, bem como os detalhes técnicos envolvendo a aquisição de sinais analógicos e conversões em dados digitais;
- Desenvolver um sistema para permitir a visualização e acompanhamento dessas medições;
- Estruturar interface do módulo de monitoramento inspirado em conceitos da *IoT* para aquisição, armazenamento e tratamento de dados;
- Aplicar o nó de sensoriamento em ambiente industrial afim de testar a eficiência do sistema;
- Comparar nó desenvolvido na pesquisa com sistema industrial usado para manutenção preditiva.

2 Revisão bibliográfica

Com o objetivo de ambientar o trabalho desenvolvido em meio a comunidade acadêmica, esse capítulo apresenta artigos e livros como referência de embasamento teórico no estudo de vibrações mecânicas, manutenção preditiva e sensores e hardware de baixo custo. Sendo assim possível avaliar as diretrizes científicas do experimento a ser realizado e quais poderiam ser os possíveis resultados esperados.

2.1 Vibrações mecânicas

A maioria das atividades humanas envolve vibração, a exemplo da audição que é um fenômeno proveniente da vibração dos tímpanos. Segundo Singiresu et al. (1995), no início do estudo de vibração, os esforços foram direcionados no entendimento de fenômenos naturais e desenvolvimento de sistemas matemáticos para descrever a vibração de sistemas físicos. Com o passar do tempo e a constatação da importância da vibração na sociedade atual, as investigações vieram para o campo da engenharia.

De acordo com Farrar e Doebling (1999), pesquisadores começaram os estudos de vibração na indústria focados no campo aeroespacial e plataformas marinhas de petróleo. Utilizavam a detecção de danos baseada em vibração durante os anos 1970 e 1980. O início das abordagens utilizadas se baseou na correlação numérica de modelos matemáticos com propriedades modais medidas de componentes danificados e não danificados (CARDEN; FANNING, 2004).

O campo de estudo mais bem sucedido de vibrações aplicados à indústria segundo Farrar e Doebling (1999) foi o monitoramento de máquinas rotativas para rastreabilidade de danos. O estudo em máquinas rotativas tem como base o reconhecimento de padrões aplicado no histórico temporal ou espectral. Os pesquisadores defendem que a partir de um banco de dados a partir da análise de vibrações medidas é possível prever danos nas máquinas no momento em que os componentes

começam a sair do padrão de funcionamento ideal.

Em geral as máquinas ou sistemas rotativos apresentam dois principais motivos para vibração: desbalanceamento e desalinhamento. O primeiro tem um componente característico de direção radial e sua frequência coincide com a frequência do eixo. Já o segundo origina vibração radial de frequência igual a do giro do eixo, porém é acompanhada de outras com o dobro e o triplo da velocidade de rotação (Arato Jr, 2004).

O banco de dados que permite uma análise temporal da máquina rotativa é alimentado através da medição de vibração por meio de uma variedade de sensores e esses dados convertidos do domínio do tempo para o domínio da frequência usando a transformada de Fourier (CARDEN; FANNING, 2004). Assim, sensores de vibração já se tornaram essenciais para a infraestrutura de manutenção preditiva especialmente em componentes substituíveis. Ao invés de substituir o componente em períodos fixos e pré determinados, a manutenção preditiva baseada em vibração permite o monitoramento em tempo real que alerta os técnicos a atuar apenas quando a falha está prestes a acontecer. Isso permite maximizar a disponibilidade do equipamento.

2.2 Manutenção preditiva

A manutenção é definida como o conjunto de ações que permitem manter ou reestabelecer um bem a um estado operacional específico (ZONTA et al., 2020). Existem três tipos de manutenção: a corretiva, a preventiva e a preditiva. Segundo Arato Jr (2004), a manutenção corretiva atua após a quebra, ou seja, se baseia em atuação emergencial. A manutenção preventiva por sua vez se baseia em um plano de manutenção fundamentado por critérios estatísticos tanto de dados do fornecedor do equipamento quanto de dados do histórico da empresa para planejar a rotina de manutenção. E a manutenção preditiva é a vertente que monitora programa de funcionamento da máquina e por meio destes, tendenciam as intervenções com base na probabilidade de falhas.

O impacto da quebra relacionada à falta ou erro de execução e planejamento de manutenção representa um total de 15 a 60 % dos custos totais de operação de toda a manufatura (HAARMAN et al., 2017). Mesmo assim empresas resistem em implementar manutenção preditiva devido ao grande investimento inicial exigido. Segundo Zonta et al. (2020) a manutenção preditiva vem ganhando grande importância para as

indústrias devido ao crescimento da capacidade das interações entre diversas partes das atividades de produção em manufatura e a conectividade com o sistema como um todo.

Aliado à conectividade no sistema de produção devido a manutenção preditiva, o conceito de *IoT* vem ganhando espaço no cenário da engenharia mecânica. Segundo Wortmann e Flüchter (2015) embora o termo *IoT* seja popular em aplicações de engenharia não existe uma definição exata para o conceito. As origens do termo surgiram há mais de 15 anos e foram atribuídas ao trabalho do *Auto-ID Labs* no *Massachusetts Institute of Technology (MIT)* em rede de infraestruturas de identificação por radiofrequência (ATZORI et al., 2010); (MATTERN; FLOERKEMEIER, 2010).

A partir dessa origem, os estudos de *IoT* passaram para além do escopo de tecnologia de identificação por radiofrequência. Segundo a União Internacional de Telecomunicações (ITU), pode-se definir *IoT* como 'uma infraestrutura global para a sociedade da informação, possibilitando serviços avançados por interconexão (física e virtual) coisas baseadas em tecnologias de informação e comunicação interoperáveis, existentes e em evolução' (ITU 2012). (MATTERN; FLOERKEMEIER, 2010).

Conectando bases de *Machine Learning* com *Big Data* através da manutenção preditiva é possível gerar um banco de dados através de aprendizados do comportamentos das máquinas obtidos por meio das medições e análises. (ZONTA et al., 2020). Um dos principais requisitos para a realização da manutenção preditiva é uma quantidade suficiente de dados de todas as partes do processo de produção (KIAN-GALA; WANG, 2018). Como resultado pode-se diminuir os custos de manutenção e o tempo de inatividade e melhorar a produtividade e qualidade também por conta do aprendizado gerado através do monitoramento.

Segundo Farrar e Worden (2012) danos em sistemas ou máquinas podem ser definidos apenas mediante a comparação entre um sistema ideal e um sistema danificado para que se possa realizar o comparativo. A comparação deve ser feita a partir do uso de uma base analítica do sistema estudado com dados históricos de comportamento e por meio de algoritmos de aprendizado de máquina define-se um padrão ideal de funcionamento e toda vez que o comportamento sai do padrão esperado um alerta deve ser gerado sobre aquele sistema. A fim de se padronizar a classificação de estado de máquinas em um sistema internacional normas ISO 2372 e NBR10082 foram criados conceitos e métricas a fim de determinar o estado do sistema a ser monitorado que será melhor detalhado no próximo capítulo.

Alinhado com a inovação da manutenção preditiva e conectividade com a internet temos também o conceito de Indústria 4.0. Conectividade, ciência de dados, novos dispositivos, redução de estoque, personalização e produção controlada deram origem à chamada Indústria 4.0. Zonta et al. (2020) define o termo como uma forma de atender as demandas de inovação e mudanças anunciadas na Alemanha como a quarta revolução industrial. Personalização e disponibilidade de dados permitindo ações por pessoas ou máquinas são algumas das características essenciais da Indústria 4.0.

Dados coletados de vários sensores em ambientes da Indústria 4.0 fornecem novas oportunidades para soluções de previsão de vida restante de um ativo Tokognon et al. (2017). A ideia de que a manutenção preditiva pode gerar alertas de ação instantâneos com base no desempenho do equipamento ou condições através do banco de dados da máquina se torna primordial para o futuro da Indústria (Wu et al., 2016).

Mahmud et al. (2018) propõe uma plataforma *IoT* para *SHM*. Um filtro *Butterworth* simples foi utilizado para a remoção de ruído juntamente com um modelo matemático para a determinação da localização e tamanho do dano na estrutura estudada. Para conexão com a nuvem a plataforma *ThingWorx* foi utilizada para armazenamento e processamento de dados em tempo real. O autor utilizou dois sensores piezoelétricos, um como gerador e outro como receptor de sinal e a estrutura a ser estudada foi posicionada entre os dois sensores. A partir do tratamento das ondas de sinais gerados e recebidos era possível estabelecer uma padrão de classificação de saúde estrutural e uma vez que as ondas demorassem mais tempo para voltar ao receptor seria possível determinar uma falha na estrutura pelo maior caminho percorrido pela onda e ainda o tamanho da falha.

Toledo et al. (2021) apresenta uma comparação em laboratório entre acelerômetros de baixo custo e comerciais afim de se comparar desempenho e confiabilidade entre os dois sistemas. O acelerômetro comercial utilizado foi o CCLD 4507B, conectado a um sistema de aquisição QuantumX MX1601B e custo de montagem de cerca de \$3000. Os acelerômetros de baixo custo foram o MPU-6050 e MPU-9250 ambos conectados a um Raspberry Pi 3 Modelo B. Ambas as montagens custam cerca de \$30. A primeira montagem utilizava cabos como conexão enquanto as duas últimas utilizavam a rede Wi-Fi do laboratório. Os testes foram realizados com a mesma taxa de aquisição constante a 600 Hz. Testes com os três sensores foram realizados em agitadores de bancada, ModalShop 2004E e Keysight 33210A para testar diferentes *inputs* de amplitude e frequência de sinal.

Toledo et al. (2021) em seu experimento avaliou o ruído dos sensores em repouso. Ambos sensores de baixo custo apresentaram maiores ruídos em comparação ao acelerômetro comercial. Concluiu que para aplicações na faixa de 0,001g os protótipos não são indicados, contudo, para acelerações maiores o uso dos protótipos torna-se viável. Ao analisar os resultados no domínio da frequência os sensores de baixo custo tiveram desempenho semelhante ao sensor comercial na faixa de teste entre 2,5 Hz e 159,2 Hz. Já no domínio do tempo as discrepâncias foram maiores visto que os sensores de baixo custo não foram calibrados para o teste realizado. O autor conclui na potencial substituição de sensores convencionais pelos de baixo custo em estudo para aplicações de *SHM* em bancada e reforça a importância de uma programação mais fina para análises de aceleração no domínio do tempo em caso de aplicação em larga escala.

2.3 Sensores e Hardware de baixo custo

Recentemente, tem-se notado um aumento no uso de sensores acelerômetros baseados em sistemas microeletromecânicos (*MEMS*, do inglês *microelectromechanical systems*) em aplicações de engenharia. Esses sistemas são caracterizado por seu tamanho compacto e baixo custo em comparação com acelerômetros piezoresistivos que são mais caros e não aconselháveis em medições de vibração por não responderem bem a *inputs* de sinais de baixa frequência. Além disso os *MEMS* tem ampla aplicação, uma vez que tais sistemas têm múltiplas funções de detecção como temperatura, aceleração e umidade (VARANIS et al., 2018).

De forma geral, os *MEMS* são uma tecnologia que envolve elementos mecânicos e eletrônicos em um pequeno chip, possibilitando a produção em tamanho pequeno, além de fornecem capacidade de multiplicidade, o que permite a fabricação de um grande número de unidades idênticas ao mesmo tempo, mantendo assim o custo final do produto baixo (JUDY, 2001).

Nas aplicações industriais e de manufatura os *MEMS* são empregados para medição de grandezas físicas como aceleração e temperatura (GAO; ZHANG, 2004). Nesta seção, o foco do estudo se concentrará nos acelerômetros *MEMS*. No trabalho de Nunes et al. (2019) esse tipo de sensor foi aplicado com o objetivo de adquirir os dados na identificação de vibração e frequência por meio da placa de prototipagem Arduino. Os resultados apresentados das frequências trouxeram resultados espera-

dos na análise de vibração como histórico temporal permitindo a tomada de decisão. Ainda assim os sistemas robustos com acelerômetros piezoelétricos apresentaram uma maior precisão.

Andò et al. (2014) também utilizaram acelerômetros *MEMS* juntamente com o Arduino como um sistema de aquisição de dados sem fio em construções civis com o objetivo de monitorar e detectar eventos críticos nas estruturas. Albarbar et al. (2009) também fizeram uma comparação entre os acelerômetros piezoelétricos com os *MEMS*. Com o auxílio de um pequeno *shaker*, um gerador de sinais e um computador para o armazenamento dos dados, foram testados com sinais de entrada do tipo excitação periódica, impulso e do tipo excitação aleatória. Dessa forma, concluíram que os *MEMS* possuíam um bom desempenho nas medições aleatórias e nas periódicas, contudo no impulso tiveram uma diferença de fase para os sensores convencionais em diferenças frequências, evidenciando uma possível deterioração nas respostas medidas.

O pequeno tamanho dos dispositivos *MEMS* também motiva o uso em alguns processos de monitoramento, como o *SHM*, monitoramento da condição de máquinas e detecção de danos. Kavitha et al. (2016) alertam que embora o *MEMS* acelerômetros têm alto potencial em processos manutenção preditiva, existem poucos sensores *MEMS* para *SHM* no mercado com a confiabilidade, sensibilidade e robustez necessárias para aplicação em campo.

O MPU-6050, módulo composto por um acelerômetro e giroscópio triaxiais, além de um sensor de temperatura, pode ser usado em muitas aplicações, sendo possível desenvolver tanto um nó de sensoriamento para estruturas como vigas em pontes baseado na integração de Arduino e sensor MPU-6050 (GALDINO; CURY, 2017) como também sistemas de sensoreamento compactos e portáteis de vibração e frequência para estudo do comportamento dinâmico de estruturas (XIAOYAN; KUANG, 2016). Ainda pode ser usado em detecção de danos para monitoramento de integridade estrutural através da velocidade angular obtidas pelo giroscópio (LIAO et al., 2016).

A aplicação dos dispositivos *MEMS* combinados com um tecnologia sem fio em redes de sensores é amplamente pesquisada na literatura, desde processos de monitoramento até coletores de energia como em Sohn et al. (2015) e Chandrasekaran et al. (2015). Além do mais, os dispositivos *MEMS* são caracterizados por seu baixo custo e consumo de energia, que são características valiosas para sensores sem fio nas aplicações dos estudos abordados nesta seção.

No entanto, existem ainda alguns problemas em redes de sensores sem fio em relação à amostragem taxa e a aquisição síncrona essenciais para essa forma de comunicação. Esses problemas são resolvidos pelos autores Huang et al. (2015) e Liu et al. (2014), onde os sistemas são projetados e desenvolvidos para monitoramento de vibração da máquina e SHM e ambos os artigos realizaram experimentos com as redes melhorando alguns recursos que permitiram o sistema ter uma taxa de amostragem melhorada e uma boa performance de aquisição com confiabilidade.

Além disso, o artigo de Bengherbia et al. (2017) apresenta nós de sensores sem fio baseados em *FPGA* para monitoramento de vibração e diagnóstico de falha para máquinas rotativas. Dispositivos *FPGA* ou *Field Programmable Gate Array* vem como sucessores dos dispositivos *WSN* ou *wireless sensor networks* criados nos anos 90. Os novos sensores oferecem maior velocidade de processamento com menor custo e maior espaço de memória para processamento sendo ideais para aplicação de *SHM*.

2.4 Considerações a respeito da leitura

As literaturas referenciadas acima abordam os fundamentos de vibração mecânica e as origens do estudo aplicados à engenharia. A vibração mecânica, como base do estudo de *SHM*, teve forte influencia na fundamentação dos estudos de vibração aplicados à aviação. Como a evolução das pesquisas foi possível desenvolver um método de correlação numérica com base temporal de comportamento dos dados para previsibilidade de falhas. Uma vez consolidado em aviação o estudo passou a ter como foco aplicação em indústria, sendo muito valioso no monitoramento de desgaste em máquinas rotativas para prevenção de danos. Ainda, como forma de popularizar a aplicação de manutenção preditiva em larga escala se tem empregado o uso de sensores *MEMS* como alternativa confiável e segura com grande aplicabilidade em indústrias por conta de seu baixo custo.

3 Fundamentação teórica

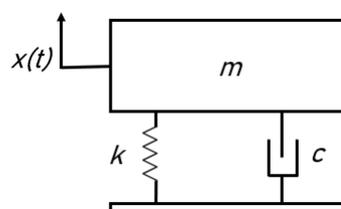
Com o objetivo de ambientar o leitor do trabalho desenvolvido em meio às teorias que envolvem o estudo de vibrações e manutenção preditiva, esse capítulo fornece as bases teóricas de fundamentos de vibração mecânica e manutenção preditiva baseada em análise de vibrações, os dois principais grandes estudos para a compreensão do experimento deste trabalho.

3.1 Fundamentos de vibrações mecânicas

Vibrações mecânicas são intrínsecas à atividades de rotina. Estão presentes em mecanismos girantes, acoplamentos, redutores, instrumentos musicais, estruturas de edifícios e pêndulos por exemplo.

Para se definir vibração no campo da manutenção, serão utilizados conceitos físicos através de um modelo vibratório que pode ser representado pela Figura 1, caracterizado pelo deslocamento da massa ao longo do tempo onde ocorre troca entre energia potencial e cinética resultando em um movimento oscilatório (Arato JR, 2004).

Figura 1 – Modelo Vibratório



Fonte: Elaborado pela própria autora

É possível representar a resposta vibratória do sistema em análise no domínio do tempo e no domínio da frequência. No domínio do tempo tem-se algumas equações que regem matematicamente os sinais vibratório. A equação 1 a representação do

deslocamento $x(t)$ de um sinal de vibração ao longo do tempo e suas variáveis representadas nas equações 2, 3, 4.

$$x(t) = X \text{sen}(\omega t + \varphi) \quad (1)$$

$$\omega = 2\pi f \quad (2)$$

$$f = \frac{1}{T} \quad (3)$$

$$\varphi = \text{sen}^{-1} \frac{X_0}{X} \quad (4)$$

onde X representa a amplitude do sinal, X_0 é o valor de amplitude inicial do sinal e T o período do sinal, o tempo de repetição periódica do sinal. Por definição velocidade e aceleração podem ser definidas matematicamente como a primeira e segunda derivada do deslocamento resultando na descrição representada nas Equações 5 e 6 respectivamente.

$$v(t) = \frac{dx}{dt} = X\omega \cos(\omega t + \varphi) \quad (5)$$

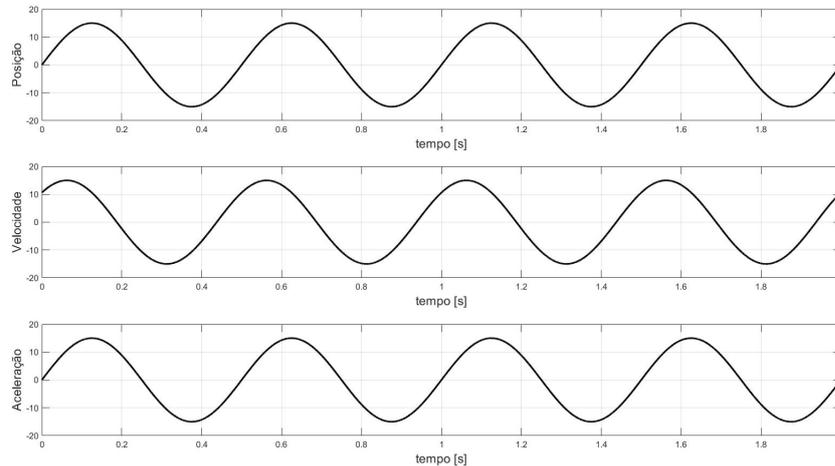
$$a(t) = \frac{dv}{dt} = -X\omega^2 \text{sen}(\omega t + \varphi) \quad (6)$$

A Figura 2 exemplifica matematicamente a relação entre as três grandezas discutidas no tópico resultantes das Equações 1, 5 e 6 mostrando o comportamento do sinal vibratório dentro de um mesmo período de tempo.

Para Arato Jr (2004), o funcionamento de um sistema real quase nunca se enquadra no formato de vibração padronizado igual ao da Figura 2. O sinal de vibração pode ser periódico, com o mesmo padrão de repetição no período, aleatório, com sinais im-

previsíveis ou transitório, quando um determinado sinal existe apenas em um certo intervalo de tempo.

Figura 2 – Relação entre Deslocamento, Velocidade e Aceleração de um movimento senoidal oscilatório



Fonte: Elaborado pela própria autora.

Segundo Franzoni et al. (2010) existem muitas técnicas de análise de vibrações em regime permanente que se baseiam em valores quantitativos globais bem difundidas no ambiente industrial para padronização da análise. Para o estudo de vibrações foram definidos quatro valores globais quantitativos para um movimento vibratório, o valor eficaz ou RMS (*root mean square*), valor médio, fator de forma e fator de crista. O valor RMS será o foco deste estudo. O valor RMS, valor eficaz de um sinal é calculado através da equação 7, sendo $x(n)$ o sinal de vibração medido e N o número de amostras do sinal. E através do valor RMS de velocidade é possível classificar o regime de operação da máquina segundo NBR 10082, abordado posteriormente.

$$x_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x(n)^2} \quad (7)$$

Já a análise de vibração pelo domínio da frequência descreve o sinal de forma espectral. Ela fundamenta em que um sistema é composto por várias máquinas vibrando e os valores das amplitude (X_i) máximas relativas a cada frequência de vibração (ω_i) compõe o sinal de vibração estudado.

Sinais periódicos são comumente analisados através da série de Fourier, que tem

como base a representação de um sinal em decomposição do mesmo em senos e cossenos como funções de frequências, amplitudes e fases relativas (SHIN, 2008). Por exemplo, uma onda quadrada pode ser interpretada como uma série de ondas senoidais e segundo Farrar e Worden (2012) essa comparação pode ser chamada de representação de Fourier.

Qualquer função $x(t)$ definida no intervalo $[-\phi/2, \phi/2]$, tem-se uma representação da função naquele intervalo representada pela equação 8 é chamada de série de Fourier.

$$x(t) = a_0 + \sum_{n=1}^{\infty} a_n \cos\left[\left(\frac{2\pi n}{\phi}\right)\phi\right] + \sum_{n=1}^{\infty} b_n \sin\left[\left(\frac{2\pi n}{\phi}\right)\phi\right] \quad (8)$$

A fim de se eliminar a periodicidade da série de Fourier tomando ϕ como ∞ e fazendo algumas manipulações matemáticas é possível chegar à transformada de Fourier mostrada na equação 9.

$$F[x(t)] = X(\omega) = \int_{-\infty}^{\infty} x(t)e^{-i\omega t} dt \quad (9)$$

A decomposição de sinais da série implica em um comportamento espectral e para uma análise que traga resultados interessantes ao estudo de engenharia é importante que o mesmo tenha comportamento periódico para que os *insights* extraídos de uma análise de vibração façam algum sentido para monitoramento de comportamento que será tratado na seção seguinte (FARRAR; DOEBLING, 1999). Também é possível tratar sinais não periódicos com a transformada de Fourier porém esse estudo não será o foco do trabalho.

3.2 Manutenção preditiva baseada em análise de vibrações

O fundamento da análise de vibrações, segundo Arato Jr (2004) consiste em estruturas das máquinas excitadas pelos esforços dinâmicos decorrentes de seu funcionamento que respondem com sinais vibratórios cuja frequência é idêntica aquela dos esforços que provocam. A análise se baseia na lógica de que a degradação de componentes da máquina geram esforços a mais no sistema em estado normal de operação

e é essa diferença de sinal que acusa o estado de saúde da estrutura. Sendo assim a análise histórica de funcionamento da máquina é necessária para que seja possível determinar o padrão de funcionamento e a partir dele ser possível determinar em que momento o desbalanceamento da máquina começa a acontecer.

Uma vez tendo a leitura de dados da análise de vibração é necessário utilizar técnicas de processamento de sinal. Atualmente, as técnicas utilizadas universalmente são: análise por nível global de vibração, espectro de vibração e média temporal síncrona.

A técnica por nível global de vibrações consiste em calcular um valor global do sinal de vibração em diferentes pontos da máquina que consiste em uma representação da medida do nível de amplitudes do seu sinal vibratório. E para classificar os níveis aceitáveis de vibração, existem normas técnicas internacionais como a ISO que definem um valor global de referência.

Para máquinas rotativas com velocidade angular entre 600 a 12.000 rpm, a norma ISO 2372 e NBR 10082 adotam valor eficaz da velocidade para categorizar a severidade da vibração. Assim, a manutenção deve acontecer quando os valores medidos atingem os valores estabelecidos pelas normas internacionais, que recomendam a intervenção no equipamento.

Além do nível global de vibração, existe a técnica de análise por espectro de vibração que consiste em analisar espectralmente o sinal vibratório lido na máquina. Ela vai resultar em picos de amplitude nas frequências associadas a excitações e quando o pico de algum dos eixos de medição destoar dos demais, significa que o sistema está desbalanceado e necessita de intervenção.

O método de análise de resultados a ser utilizado neste estudo será o método de monitoramento pelo critério da velocidade eficaz de vibração, velocidade RMS. A norma ISO 2372: Vibrações mecânicas de máquinas com velocidades de operação de 10 a 200 rotações por segundo - Base para especificação de padrões de avaliação, classifica os níveis de vibração em 15 faixas discretizadas na Tabela 1

Tabela 1 – Faixas de severidade de vibração segundo NBR 10082

Intervalo de velocidade RMS [mm/s]	Faixa
0,071 a 0,112	0,11
0,112 a 0,18	0,18
0,18 a 0,28	0,28
0,28 a 0,45	0,45
0,45 a 0,71	0,71
0,71 a 1,12	1,12
1,12 a 1,8	1,8
1,8 a 2,8	2,8
2,8 a 4,5	4,5
4,5 a 7,1	7,1
7,1 a 11,2	11,2
11,2 a 18	18
18 a 28	28
28 a 45	45
45 a 71	71

Fonte: Adaptada de NBR 10082.

Com base na norma ISO, a norma NBR 10082 foi redigida classificando os níveis de vibração em classes de operação mostradas na Tabela 2 e através da análise das duas tabelas é possível chegar ao nível de operação da máquina em análise sendo:

- Nível A: Boa condição, resultado comum após calibração da máquina;
- Nível B: Aceitável, resultado comum em máquinas com manutenção regular e operacionalidade dentro do esperado;
- Nível C: Limite tolerável, resultado não aceitável para operação contínua. Nesse caso de operação é necessário programar revisão para reajuste o mais rápido que se puder;
- Nível D: Não permissível, resultado inaceitável visto que o tipo de operação é danosa para a máquina avaliada. Deve-se realizar manutenção corretiva imediatamente.

A Tabela 2 se baseia na NBR 10082 e classifica o nível de operação das máquinas através de sua potência e condições de operação. É através dessa classificação

que tendo em vista a velocidade RMS de operação pode-se definir a severidade de funcionamento da máquina.

Tabela 2 – Classes de operação segundo NBR 10082

Classe	Descrição
Classe 1	Máquinas pequenas de potência até 15kW com acionamento por motor elétrico
Classe 2	Máquinas médias com potência entre 15 e 75kW motores montados rigidamente com potência de até 300kW
Classe 3	Máquinas motrizes com potência maior que 75kW com massa rotativa montada em fundação rígida e pesada
Classe 4	Máquinas do tipo classe 3 montadas sob fundações relativamente flexíveis

Fonte: Adaptada de NBR 10082.

A norma NBR classifica o tipo de operação da máquina exibidos na Tabela 2 e as faixas de operação definidas por norma ISO na Tabela 1 para determinar o nível de severidade de funcionamento da máquina através da Tabela 3.

Tabela 3 – Classificação das máquinas por nível de severidade segundo NBR 10082

Faixa	Avaliação			
	Classe 1	Classe 2	Classe 3	Classe 4
0,28	A	A	A	A
0,45	A	A	A	A
0,71	A	A	A	A
1,12	B	A	A	A
1,8	B	B	A	A
2,8	C	B	B	A
4,5	C	C	B	B
7,1	D	C	C	B
11,2	D	D	C	C
18	D	D	D	C
28	D	D	D	D
45	D	D	D	D
71	D	D	D	D

Fonte: Adaptada de NBR 10082.

4 Materiais e métodos

A lógica de desenvolvimento do módulo de sensoriamento e toda pesquisa desenvolvida para aplicação em campo do experimento em estudo assim como máquina estudada e condições de operação de ambos foram detalhados ao longo deste capítulo.

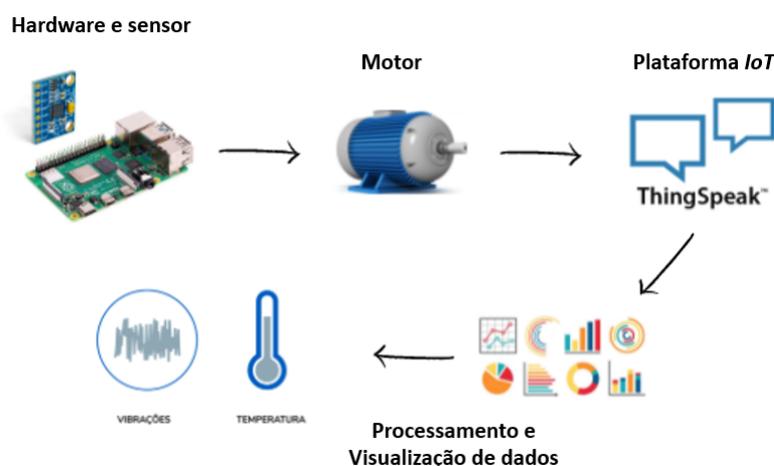
4.1 Descrição do sistema de medição implementado

A fim de se obter os resultados esperados neste trabalho foi necessário o desenvolvimento de uma lógica para aquisição e tratamento de dados. Com base nas literaturas descritas nos capítulos anteriores e estudos e experimentos realizados pelos respectivos autores foi possível esboçar a lógica do nó de sensoriamento em estudo.

A lógica implementada pode ser observada na Figura 3 e consiste em um monitoramento do motor em estudo via módulo de sensoriamento: sensor, *hardware* e plataforma *IoT*. O sensor utilizado no estudo foi o MPU6050 conectado a um Raspberry Pi 4 atuando como *hardware* integrado à plataforma *IoT*, ThingSpeak, que mediam um motor Weg de 3kW de potência e 1800 rpm.

O sensor MPU-6050 é um dispositivo que integra acelerômetro e giroscópio de três eixos, além de sensor de temperatura em um chip com dimensões de 4 mm × 4 mm × 0,9 mm. Como o MPU-6050 é de tamanho muito pequeno e deve ser alimentado com uma tensão entre 2,375 e 3,46 V, é montado em uma placa de *breakout* que permite que a placa seja alimentada com uma tensão de até 5 V. Isso faz com que o mesmo apresente diversos campos de aplicação, como celulares, aeromodelos, bússolas e niveladores. As principais especificações técnicas do MPU-6050 são ilustradas na Tabela 4.

Figura 3 – Fluxograma do sistema de Medição Implementado



Fonte: Elaborado pela própria autora.

Tabela 4 – Especificações MPU 6050

Parâmetro	Valor
Tensão de Alimentação	2,375V - 3,46V
Corrente do Giroscópio	3,6 mA
Corrente Acelerômetro	500 A
Faixa do Giroscópio	$\pm 250, 500, 1000, 2000^{\circ}/s$
Faixa do Acelerômetro	$\pm 2, \pm 4, \pm 8, \pm 16g$
Faixa de Medição de Temperatura	$-40^{\circ}C$ a $85^{\circ}C$
Sinal de Saída	Interface I2C
Dimensões	$21 \times 15 \times 2$ mm
Massa	1,2 g

Fonte: Elaborado pela própria autora.

Como módulo de aquisição e processamento de dados foi utilizado o Raspberry Pi, um computador de placa única de ampla aplicação no campo da tecnologia para o desenvolvimento do presente estudo. O dispositivo foi criado no Reino Unido pela Fundação Raspberry Pi, uma organização sem fins lucrativos focada no incentivo do ensino de ciência da computação básica para jovens em escolas e universidades (YAMANOOR SRIHARI, 2017). Segundo o autor as aplicações atendem desde o desenvolvimento de jogos até aplicação em aulas para reprodução de áudios e vídeos de forma inovadora no aprendizado.

O modelo utilizado no estudo em questão foi o Raspberry Pi 4 o modelo mais recente desenvolvido pela empresa que tem tensão de alimentação de até 6 V

e corrente de 3 A, sistema operacional Linux, suporta temperatura de operação até 50°C , tem conexão Wi-Fi, USB, suporte à cartão de memória SD e saída HDMI. Mais detalhes das especificações técnicas da placa são detalhadas na Tabela 5

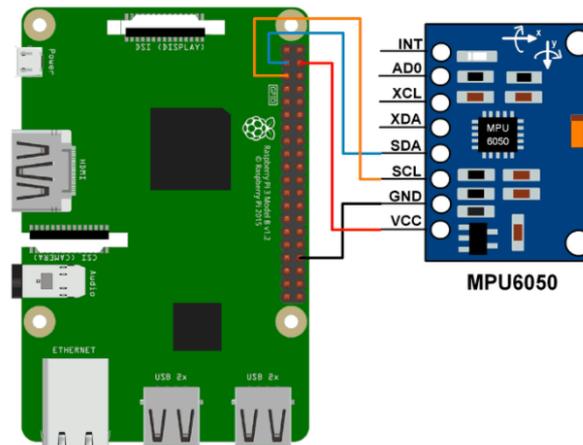
Tabela 5 – Especificações Raspberry Pi 4

Parâmetro	Valor
Tensão de Alimentação	-0.5V a 6 V a 3 A
Hardware	Quad core 64-bit
	VideoCore VI 3D Graphics HDMI display
Principais Interfaces	802.11 b/g/n/ac Wireless LAN
	Bluetooth 5.0
	cartão SD
	micro-HDMI USB 2 e 3 portas
Software	Linux
Temperatura de operação suportada	de 0 a 50°C

Fonte: Adaptado de Raspberry datasheet.

O Raspberry Pi possibilita a montagem de um computador caseiro quando conectado a um monitor, teclado e mouse. Apesar de ser limitado comparado a um computador completo, executa de maneira satisfatória programas básicos de computação e suporta sistema operacional Linux. No experimento em questão, a conexão entre o sensor e a plataforma *IoT* foi programada em Python, linguagem de programação de ampla interface com vários módulos, se mostrando muito versátil para a pesquisa e para prototipagem rápida.

Figura 4 – Ligação Raspberry e MPU-6050

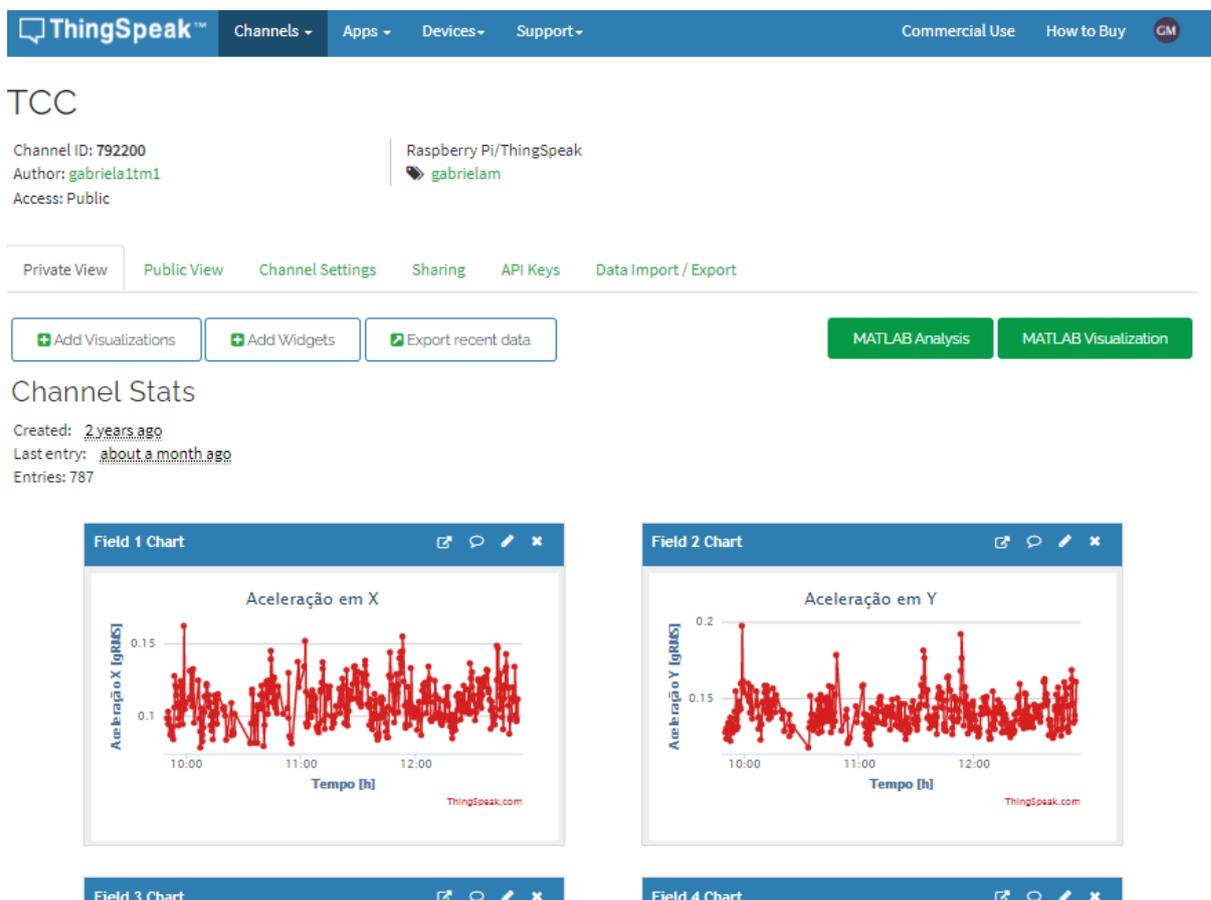


Fonte: EletronicWings

Por fim, a plataforma em nuvem utilizada no experimento foi o ThingSpeak™: o *software* de uma interface simples e fácil navegação para análise de dados ilustrada na Figura 5. Nessa etapa a plataforma é utilizada como armazenamento, processamento e visualização de dados, etapa final da lógica explicitada na Figura 3.

A conexão entre o *hardware* e o sensor é representada esquematicamente na Figura 4 . Para conectar a leitura do sensor em nuvem, foi utilizado uma lógica de programação em Python, apresentada no Apêndice 6, para ativação do sensor e tratamento dos dados de saída e ainda conectar com o banco de dados do site ThingSpeak que fornece uma chave API de conexão com o código de fácil manipulação. A plataforma é *open-source*, permite construir sistemas sem configurar servidores ou desenvolver *software* da web, possui comunidades de apoio e suporte para construção em conjunto com a comunidade e também oferece suporte e integração com Arduino®, Raspberry Pi e outros *hardwares*. Nesse experimento a integração entre a placa e a plataforma ThingSpeak™ foi considerada a base do conceito de *IoT* já abordado anteriormente.

Figura 5 – Interface ThingSpeak™



Fonte: https://thingspeak.com/channels/792200/private_show

4.2 Descrição do setup experimental

Através da definição do sistema de medição e da especificação de funcionamento de cada componente do nó de sensoriamento foi possível definir a máquina de estudo. Desde a concepção inicial do estudo o local desejado para teste do módulo de medição era um sistema fabril a fim de se comprovar a aplicabilidade e confiabilidade do nó desenvolvido.

A autora do estudo estagiou em uma indústria de bens de consumo, a AmBev, possibilitando assim a aplicação do experimento em campo. A planta de estudo foi uma fábrica de refrigerantes, com produção de xarope, oito linhas de envase e toda a estrutura de utilidades disponível para aplicação do sensoriamento desenvolvido.

Algumas áreas da fábrica, como utilidades e linhas de envase, contavam com sistema industrial de medição preditiva - sensores com conexão a plataformas *IoT* para

processamento e visualização de dados. Sendo assim, além de testar o sensoramento desenvolvido em estudo para este trabalho, ainda foi possível comparar os dados com um sistema industrial no mesmo ambiente de simulação.

Dentre as várias máquinas disponíveis para estudo, a escolhida foi o motor de um forno ilustrado na Figura 6, da empacotadora de uma das linhas de envase cujas informações técnicas estão expostas na Tabela 6. Esse motor é responsável pela circulação do ar através das resistências pra fazer a retração do filme de envolvimento do pacote.

Classificando o motor com base na norma NBR 10082 da Tabela 2 tem-se que o motor escolhido pertence à Classe 1: motores de máquinas pequenas de potência até 15 kW.

Tabela 6 – Especificações Motor de Estudo

Parâmetro	Valor
Fabricante	WEG
Modelo	W22 IR3
Rotação	1800 rpm
Potência	3 kW
Temperatura Máxima de Operação	80 °C

Fonte: Elaborado pela própria autora.

Figura 6 – Motor de estudo



Fonte: Elaborado pela própria autora.

O motor foi escolhido por atuar em uma máquina crítica da linha por ser uma máquina antiga, sujeita a temperaturas relativamente altas, o *setup* do forno opera em

180 °C, grande contato com açúcar e poeira por estar em uma linha de envase de refrigerante e perto do armazém de produto acabado.

O módulo de medição utilizado na fábrica era o sensor da startup Tractian: um acelerômetro triaxial X, Y e Z - o Band Trac ilustrado na Figura 7, que tem horímetro, medição de vibração, temperatura e consumo de energia. Esse dispositivo conecta ainda os sensores à uma plataforma *IoT*. As especificações do Band Trac são mostrados na Tabela 7. Além de tudo, não há necessidade de *gateways* ou infraestrutura própria para salvar e analisar esses dados, o sensor conta com um chip de conexão com internet e não depende de conexão com a rede da planta.

Figura 7 – Sensor Band Trac



Fonte: Tractian.

Tabela 7 – Especificações BandTrac

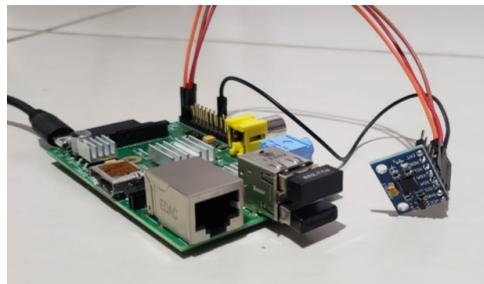
Parâmetro	Valor
Alimentação	5V / 1A
Temperatura de operação	-30 a 80 °C ± 0,1 °C
Vibração	1Hz a 6.6kHz 5s de coleta a cada 10min
Dimensões	82 mm x 42 mm x 29 mm
Índice de Proteção	IP65 – resistente a poeira e jatos d'água não potentes
Conectividade	Rede Vivo 2.5G / 2G ou Rede Claro GPRS ou Fallback Wi-Fi

Fonte: Adaptado de Tractian.

O nó de sensoriamento desenvolvido para o experimento é mostrado na Figura 8 e como se pode ver na Figura 9 foi instalado no motor da Figura 6. Para fixar o sensor no motor do experimento, foi necessário o auxílio de uma fita dupla face da fabricante

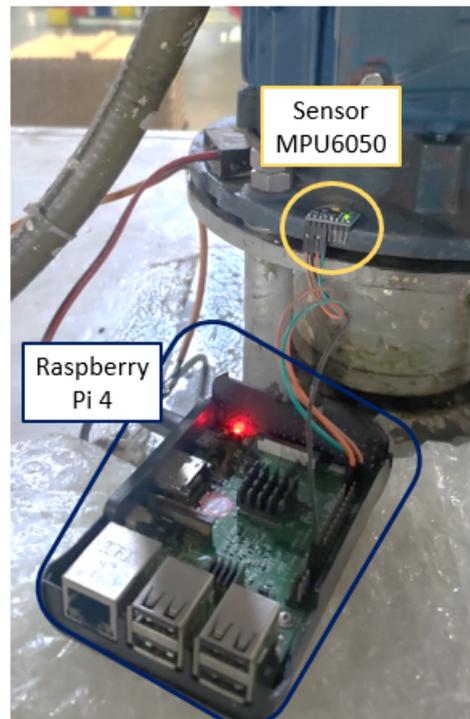
3M como pode se ver na Figura 10. A existência da fita dupla face como um adicional do sistema pode ser considerada como um amortecedor de vibração antes mesmo do sinal a ser medido chegar ao sensor de aquisição. Durante a seção de resultados essa variável será discutida. A fixação do sensor foi feita na base do motor visto que além da fácil aplicação pela disposição do MPU-6050 é um local de alta sensibilidade de desbalanceamento porque está alinhado com o eixo principal do motor. Ainda, devido a sensibilidade da placa Raspberry Pi como hardware de coleta, foi necessário um sistema de amortecimento com espuma para minimizar a trepidação da placa.

Figura 8 – Sistema de Medição Desenvolvido



Fonte: Elaborado pela própria autora

Figura 9 – Sistema de Medição Desenvolvido no Motor em estudo



Fonte: Elaborado pela própria autora

Figura 10 – Fixação Sensor MPU6050 no motor em estudo



Fonte: Elaborado pela própria autora

4.3 Metodologia dos experimentos realizados

O experimento em campo citado nas seções anteriores teve algumas complicações em seus testes iniciais. O protótipo inicial foi construído utilizando o *hardware* Raspberry Pi 1. Esse modelo de Raspberry não tem a placa integrada com Wi-Fi, sendo necessário utilizar um *dongle* para conexão com a internet. O modelo também não possuía um estojo de proteção que deixava o sistema muito instável por conta da vibração da máquina a qual o motor a ser medido se encontrava. Consequentemente a vibração da máquina gerava uma vibração entre a placa e o *dongle* causando instabilidade no sistema de conexão com a internet. Como tentativa de contornar o problema foi feita uma base de papelão para apoio na superfície da máquina. A fixação do sensor foi feita com a fita dupla face, como pode ser visto na Figura 11 (a).

Apesar de eficiente em testes de bancada, o primeiro protótipo em campo não suportou a vibração do sistema fazendo com que fosse necessário um sistema de *hardware* mais robusto para o ambiente fabril. Como já citado anteriormente, a empresa desenvolvedora do hardware escolhido para estudo desenvolveu vários modelos de computadores de baixo custo e os modelos foram ficando mais robustos com a atualização de suas versões.

Figura 11 – Evolução das configurações experimentais



(a) Protótipo 1 : Raspberry 1



(b) Protótipo 2 : Raspberry 4

Fonte: Elaborado pela própria autora

O Raspberry Pi 1 foi substituído pelo Raspberry Pi 4 que possui conexão Wi-Fi integrada na placa, possibilitando com que a conexão com a internet do módulo fosse menos suscetível às vibrações da máquina a ser monitorada. A montagem do nó de medição foi feita da mesma forma que no primeiro protótipo como pode ser observado na Figura 11.

A nova configuração com *hardware* de Wi-Fi integrado na placa, conferiu maior estabilidade ao sistema de aquisição e mesmo assim por precaução e aprendizado do primeiro protótipo foi utilizado uma espuma como amortecedor entre a máquina e o nó de sensoriamento já que a máquina opera em condições de trabalho robustas e a Raspberry Pi mostrou-se um *hardware* não totalmente adequado para medições industriais com objetivo acadêmico para esse estudo.

Apesar das complicações iniciais descritas, foi possível realizar a coleta de dados do motor durante um intervalo de três horas, das 10h00 às 13h00 do dia 11/09/2021. Em paralelo a medição do protótipo desenvolvido neste trabalho também foi possível coletar os dados do sistema de manutenção preditiva já existente na planta para posterior análise e comparação. O nó desenvolvido tem um tempo de aquisição de dados a cada 20 segundos e o sensor Traction coleta dados a cada 10 minutos. A taxa de

amostragem do módulo desenvolvido é de 0,005 segundos e o do Tractian é de 5 minutos . A quantidade de bits do módulo desenvolvido e do Tractian é de 16 bits.

Os dados do módulo de sensoriamento foram coletados em forma de aceleração nos três eixos medidos em gravidade [g]. Para comparação com as normas citadas foi necessário realizar a transformação de unidade de medição de aceleração em [g] para velocidade em mm/s . Como a frequência dos três eixos também foi também capturada, a conversão foi realizada através das equações 10, 11 e 12 abaixo podendo-se assim chegar a unidade de comparação correta para a comparação com a norma.

$$a[mm/s^2] = 9800a[g] \quad (10)$$

$$f[rad/s] = 2\pi f[Hz] \quad (11)$$

$$v[mm/s] = \frac{a[mm/s^2]}{f[rad/s]} \quad (12)$$

5 Análise dos resultados

Os estudos sobre vibração, manutenção preditiva e sensores e hardware das seções anteriores permitiram o desenvolvimento de um módulo de sensoriamento com a finalidade de medir aceleração e temperatura de uma máquina rotativa. A lógica de desenvolvimento e implementação do experimento foi detalhada na seção anterior e os resultados obtidos neste trabalho serão mostrados a seguir.

5.1 Resultados Teste em Campo

O motor em estudo faz parte do forno de uma empacotadora das linhas de produção composta por sopradora, enchedora, rotuladora, empacotadora e paletizadora. Durante o período de aquisição de dados o motor estava funcionando em sua condição normal de operação. O motor é responsável pela circulação de ar nas placas de resistência que aquecem o forno para a contração do filme que envolve o pacote.

Entre às 10h00 e 11h30 o forno estava operando sem a entrada de garrafas para serem empacotadas, ou seja, só estava mantendo a temperatura constante. A partir das 11h30 foi liberada a entrada de garrafas e então o forno trabalhou para manter a temperatura no *setpoint* de 180 °C enquanto também recebia a entrada de garrafas.

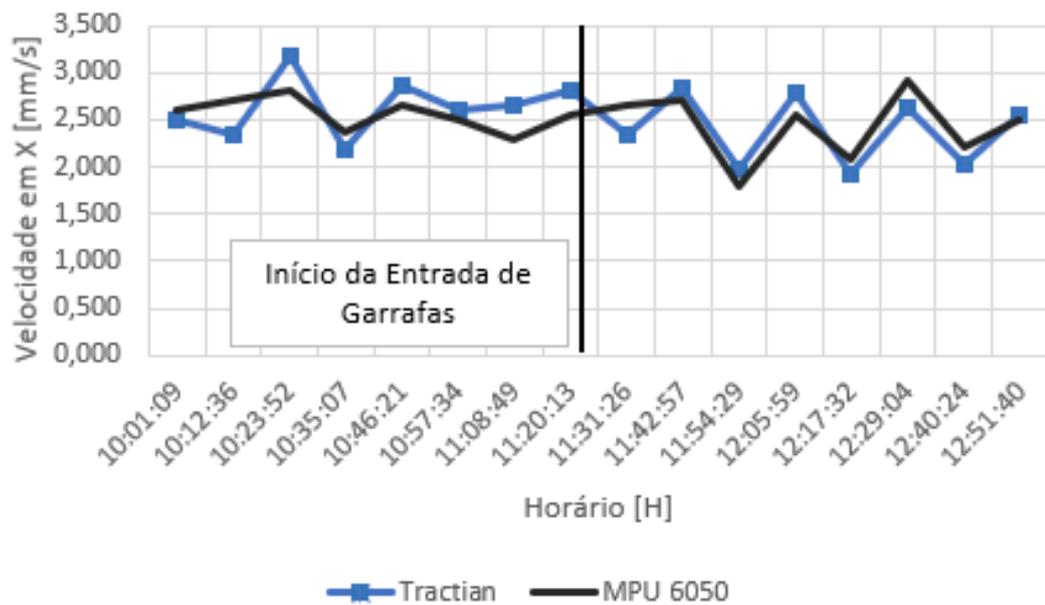
Ao todo, o módulo de monitoramento desenvolvido para o estudo coletou 400 pontos de análise enquanto o sensor Tractian coletou apenas 16 devido às diferentes configurações de aquisição. Mesmo com essa diferença os resultados podem ser comparados visto que o regime de trabalho do motor não apresenta grandes variações apenas alguns pontos fora em divergência que podem ser erro de leitura ou vibrações externas ao sistema por intervenção manual durante o experimento que serão discutidas a seguir.

Para exibição mais clara dos resultados foram utilizados somente 16 pontos do nó de sensoriamento coletado ao mesmo tempo em ambos dispositivos de medição. Os

gráficos com todos os pontos de coleta do protótipo desenvolvido podem ser analisados nas Figuras 13, 15, 17 e 19 apenas como comparação entre comportamento e tendência das curvas.

Como citado anteriormente com base nas Tabelas 2 e 6 o motor em estudo pertence à Classe 1 segundo NBR10082 e essa classificação será considerada para todas as análises a seguir.

Figura 12 – Velocidade RMS em X



Fonte: Elaborado pela própria autora.

Analisando o gráfico que contém as duas curvas de aquisição ilustrado na Figura 12 acima e com base nas Tabelas 1 e 3 pode-se classificar o nível e severidade de funcionamento do motor no eixo X conforme detalhado na Tabela 8. Através dos valores obtidos pelos dois dispositivos foi possível encontrar uma correlação matemática de 0,73 entre as duas medições.

Tabela 8 – Classificação de nível de operação do motor medido pelo eixo x

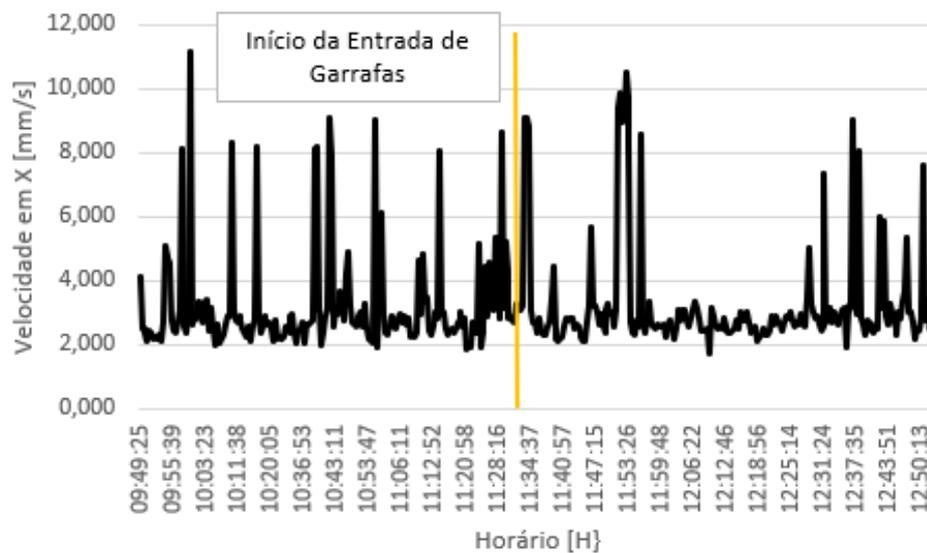
Dispositivo	Intervalo de velocidade RMS [mm/s]	Faixa	Nível de severidade de funcionamento
MPU 6050	1,8 a 2,8	2,8	C
Tractian	2,8 a 4,5	4,5	C

Elaborado pela própria autora.

A Figura 13 ilustra todos os pontos de coleta adquiridos pelo nó de sensoriamento.

Apresenta alguns picos de velocidade fora da sua curva de comportamento base. Os *outliers* perceptíveis no gráfico podem ser decorrentes de erros de medição ou falhas na conexão com o banco de dados durante o experimento. Ainda poderiam indicar desbalanceamento de algum componente porém como a tendência de comportamento dos gráficos das Figuras 12 e 13 seguem a mesma tendência, pode-se concluir que são falhas na medição.

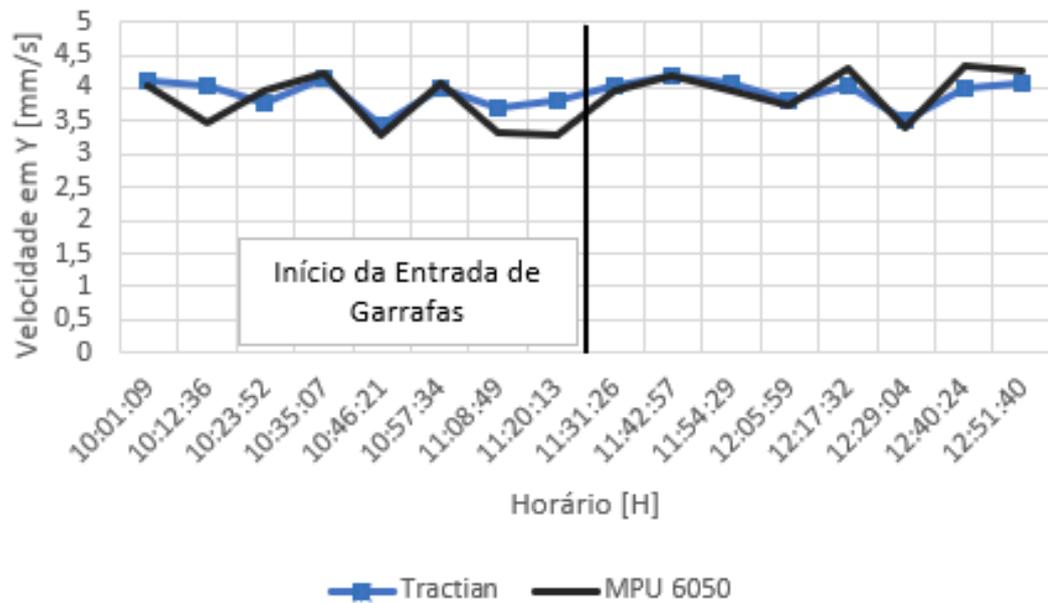
Figura 13 – Velocidade RMS em X nó de sensoriamento



Fonte: Elaborado pela própria autora.

Analisando o gráfico ilustrado na Figura 14 com as mesmas premissas da primeira análise temos a classificação do nível de severidade através da Tabela 9. Através dos valores obtidos pelos dois dispositivos foi possível encontrar uma correlação matemática de 0,78 entre as duas medições. Os *outliers* perceptíveis no gráfico podem ser decorrentes de erros de medição ou falhas na conexão com o banco de dados durante o experimento como já discutido anteriormente para as medições no eixo x.

Figura 14 – Velocidade RMS em Y



Fonte: Elaborado pela própria autora.

Tabela 9 – Classificação de nível de operação do motor medido pelo eixo y

Dispositivo	Intervalo de velocidade RMS [mm/s]	Faixa	Nível de severidade de funcionamento
MPU 6050	1,8 a 2,8	2,8	C
Tractian	2,8 a 4,5	4,5	C

Elaborado pela própria autora.

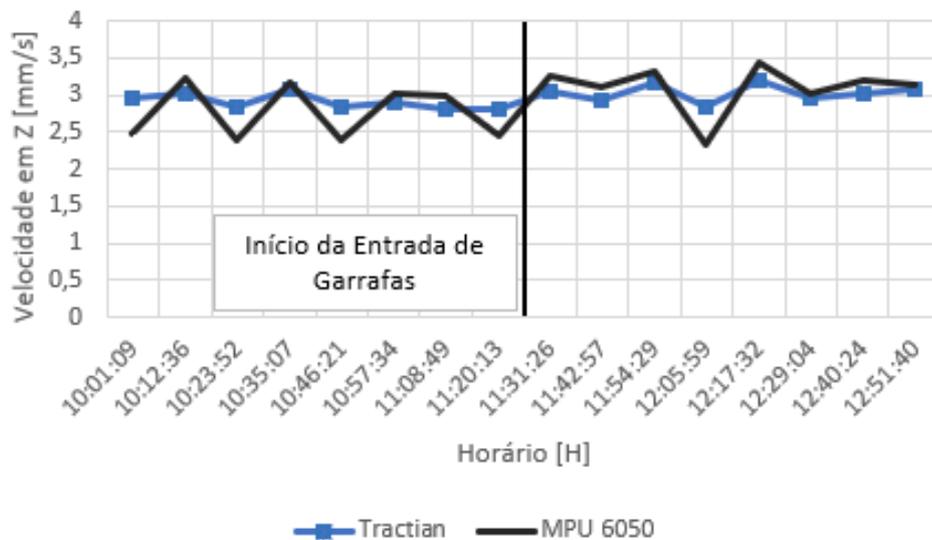
Figura 15 – Aceleração RMS em Y nó de sensoriamento



Fonte: Elaborado pela própria autora.

O gráfico ilustrado na Figura 16 apresenta sua classificação de nível de severidade conforme a Tabela 10. Através dos valores obtidos pelos dois dispositivos foi possível encontrar uma correlação matemática de 0,82 entre as duas medições. O *outlier* perceptível no gráfico pode ser decorrente de erros de medição ou falhas na conexão com o banco de dados durante o experimento como já discutido anteriormente para as medições em x e y.

Figura 16 – Velocidade RMS em Z



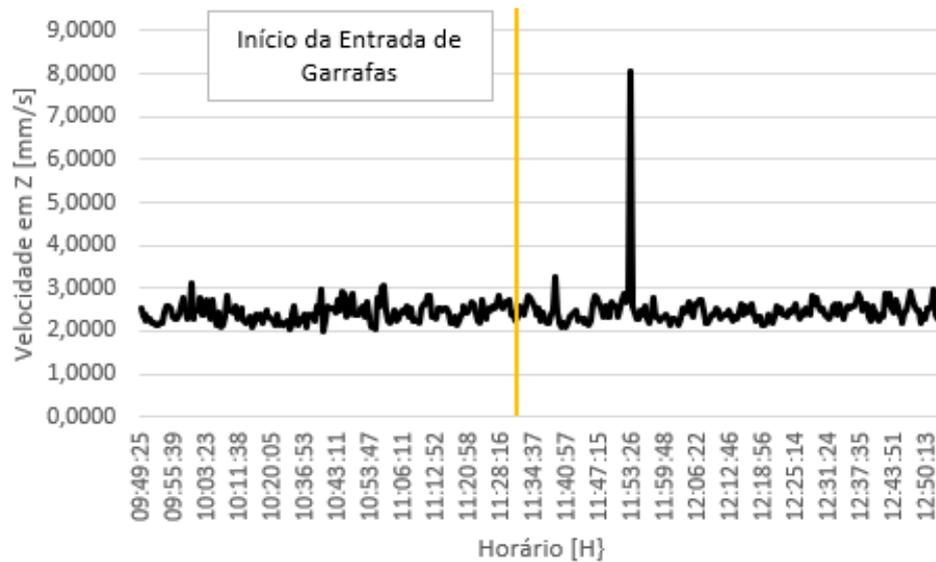
Fonte: Elaborado pela própria autora.

Tabela 10 – Classificação de nível de operação do motor medido pelo eixo z

Dispositivo	Intervalo de velocidade RMS [mm/s]	Faixa	Nível de severidade de funcionamento
MPU 6050	2,8 a 4,5	4,5	C
Tractian	2,8 a 4,5	4,5	C

Elaborado pela própria autora.

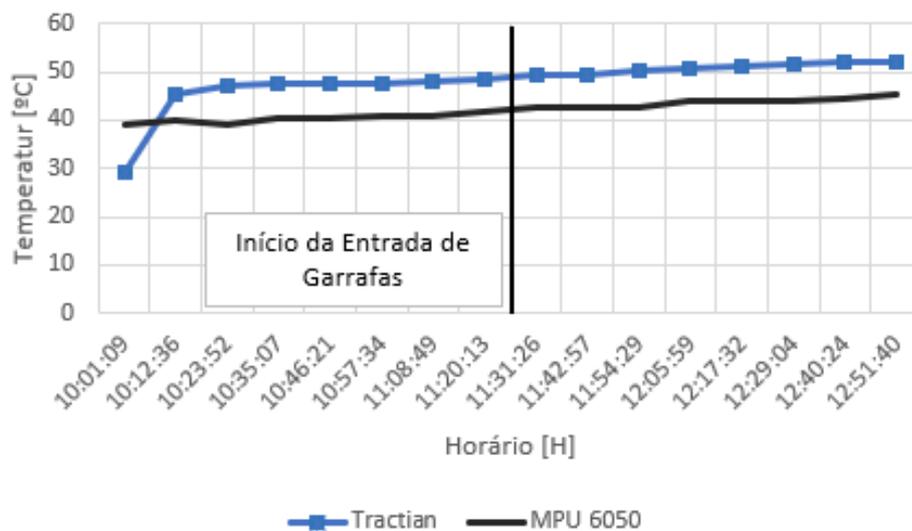
Figura 17 – Aceleração RMS em Z nó de sensoriamento



Fonte: Elaborado pela própria autora.

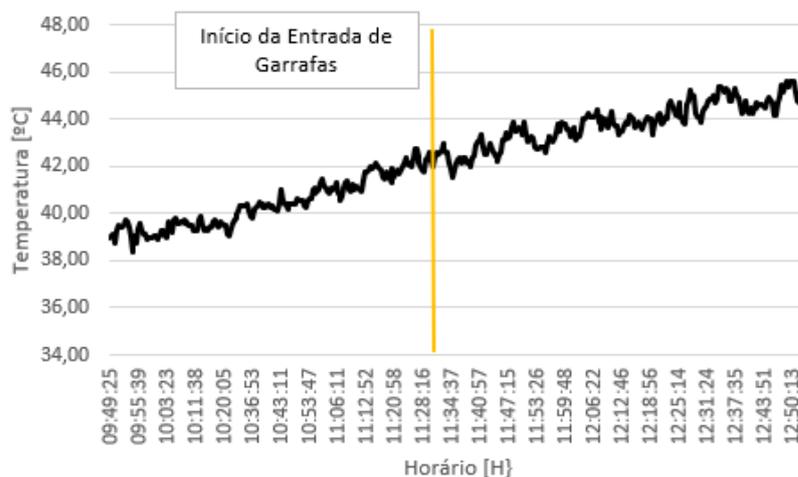
O gráfico da Figura 18 apesar de apresentar linha de tendência entre os dois modos de aquisição bem homogênea é o parâmetro de aquisição com maior diferença de valor com uma média de diferença de 115% entre os valores entre o sensor MPU-6050 e o Tractian e correlação matemática de 0,70. O aumento de temperatura durante o experimento pode ter sido ocasionado devido ao efeito da temperatura ambiente no motor.

Figura 18 – Temperatura



Fonte: Elaborado pela própria autora.

Figura 19 – Temperatura nó de sensoriamento



Fonte: Elaborado pela própria autora.

É possível concluir através da leitura dos gráficos acima que apesar de uma diferença nos valores entre as curvas de aquisição dos sensores MPU-6050 e o Tractian, as linhas de velocidade e temperatura tem a mesma tendência de comportamento além de apresentarem uma correlação matemática aceitável, maior do que 70% em todas as variáveis de medição.

Também pode-se observar através de comparação entre os valores dos três eixos, que os valores de aceleração em Y foram mais significativos sendo já esperado que uma análise de vibração desse tipo devido ao eixo Y ser perpendicular ao eixo do motor sendo o eixo que recebe a medição de toda a massa se movimentando ao redor do eixo de giro. E em caso de desbalanceamento é esse eixo que acusa vibração anômala. O eixo de representação axial evidenciará vibração em casos de folga ou desalinhamento do eixo.

Conclui-se também que a fita dupla face para fixação do sensor não teve interferência significativa como absorção de vibração no sistema desenvolvido por conta da correlação entre as curvas dos dois métodos de aquisição, mesmo com a fita o módulo não apresentou diferença significativa de valores em relação ao sensor Tractian que não possuía nenhum atenuador de vibração.

A diferença entre os valores dos dois métodos de aquisição podem ser devido à programação do MPU-6050 e sensibilidade diferente dos sensores. O intuito do estudo era o estudo da aplicabilidade do protótipo desenvolvido sendo possível se comprovar, com todas as limitações descritas ao longo do texto, através do comportamento e tendência de coleta dos dois métodos comparados.

6 Conclusões

Este trabalho teve como propósito o desenvolvimento e aplicação de um módulo de sensoriamento de baixo custo para o monitoramento de saúde estrutural de uma máquina rotativa. O protótipo desenvolvido teve desde sua concepção inicial até sua aplicação em campo o objetivo de adquirir os dados de forma confiável para incentivar a popularização da realização de manutenção preditiva. Para esse fim, o trabalho realizou a comparação do módulo de sensoriamento desenvolvido com um sensor comercial em um experimento em campo para comparar o desempenho, qualidade dos dados e aplicabilidade dos mesmos.

O experimento foi realizado em um período de três horas durante o funcionamento regular do motor em estudo. Como o módulo de sensoriamento desenvolvido no trabalho havia sido calibrado anteriormente em bancada foi possível obter resultados satisfatórios em comparação aos resultados do sensor comercial Tractian. Nos três eixos de aquisição foi obtido uma correlação superior a 0,7 indicando alta tendência de comportamento entre os dois métodos de aquisição. Ainda para os resultados obtidos em temperatura existe uma boa correlação de tendência em 0,7 com *offset* de aquisição podendo ser ajustado via calibração.

O módulo desenvolvido tem algumas vantagens em relação ao sensor comercial. Da parte de custos de aquisição, o módulo exige um investimento único em torno de R\$800,00 com Raspberry e Sensor MPU-6050, de fácil programação e aplicação em campo com grande durabilidade. Em caso de substituição de componentes como sensor ou cabos, são necessárias poucas peças de estoque para reposição e de baixo custo. Ainda que seja necessário a troca da placa do *hardware* sua reposição é facilmente encontrada pela internet. O Tractian funciona com a política de aluguel de R\$ 500,00 por sensor com contrato mínimo de 5 sensores durante 4 meses totalizando em um ano R\$6.000,00 por sensor. Ainda, por ser um sistema fechado em relação ao módulo de sensoriamento desenvolvido neste trabalho, o Tractian não permite a troca de componentes, encarecendo assim futuras manutenções no dispositivo.

Do ponto de vista de instalação, o sensor comercial tem base magnética e só necessita de aproximação física com a base para sua fixação. Já o módulo desenvolvido necessita de uma fita dupla face para a fixação do sensor no motor. Ambos sistemas exigem um manual simples de instrução para instalação na máquina. Embora o módulo desenvolvido seja de fácil aplicação, ainda existem oportunidades de aperfeiçoamento na instalação do mesmo. A necessidade de utilização de uma fita dupla face poderia ser substituída por uma montagem por parafusos ou base magnética, sem a necessidade de um elemento entre a máquina e o módulo desenvolvido.

Em quesito de experiência do usuário o módulo desenvolvido está em desvantagem em relação ao sensor comercial. A empresa Tractian disponibiliza junto com o sensor uma plataforma de monitoramento dos dados adquiridos em tempo real e essa plataforma está programada para gerar alertas via *e-mail* ou *WhatsApp* em caso de desbalanceamento ou comportamentos anômalos da máquina. É possível também atrelar ordens de manutenção a cada máquina conectada ao sistema. Fornece também a análise espectral dos sinais adquiridos. Já o módulo desenvolvido apresenta apenas a interface da plataforma ThingSpeak com os gráficos dos dados em tempo real.

A conexão com a internet dos dois métodos se mostrou bastante eficaz no experimento embora seja interessante aprimorar o módulo desenvolvido para conexão via chip integrado na placa, sem a dependência de Wi-Fi externo ao sistema como o Tractian.

Em resumo, o módulo proposto pode atuar como uma substituição potencial de baixo custo de sistemas comerciais para aplicações de *SHM*. Para aplicações industriais de larga escala é necessário trabalhar na robustez do modelo com os pontos citados anteriormente.

Como futuros desenvolvimentos para o módulo desenvolvido neste trabalho a autora sugere o aperfeiçoamento da robustez em questão de montagem do módulo: fixação do sensor na máquina, conexão do sensor com o *hardware* e fonte de alimentação do sistema independente. Como experiência do usuário o módulo também tem grandes oportunidades e pode usar como inspiração a interface do Tractian, conectar um canal de mensagens que avise o usuário do estado da máquina e ordens operacionais por exemplo.

Referências

ALBARBAR, A.; BADRI, A.; SINHA, J. K.; STARR, A. Performance evaluation of mems accelerometers. **Measurement**, v. 42, n. 5, p. 790 -- 795, 2009. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0263224108002091>>.

ANDÒ, B.; BAGLIO, S.; PISTORIO, A. A low cost multi-sensor strategy for early warning in structural monitoring exploiting a wavelet multiresolution paradigm. **Procedia Engineering**, v. 87, p. 1282 -- 1285, 2014. ISSN 1877-7058. {EUROSENSORS} 2014, the 28th European Conference on Solid-State Transducers. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1877705814028033>>.

Arato Jr, A. **Manutenção preditiva usando análise de vibrações**. [S.l.]: Barueri: Manole, 2004.

ASHTON, K. et al. That 'internet of things' thing. **RFID journal**, v. 22, n. 7, p. 97--114, 2009.

ATZORI, L.; IERA, A.; MORABITO, G. The internet of things: A survey. **Computer networks**, Elsevier, v. 54, n. 15, p. 2787--2805, 2010.

BANDARA R. P.; CHAN, T. H. T. Structural damage detection method using frequency response functions. p. 1--5, 2014.

BENGHERBIA, B.; ZMIRLI, M. O.; TOUBAL, A.; GUESSOUM, A. Fpga-based wireless sensor nodes for vibration monitoring system and fault diagnosis. **Measurement**, Elsevier, v. 101, p. 81--92, 2017.

CARDEN, E. P.; FANNING, P. Vibration based condition monitoring: a review. **Structural health monitoring**, Sage Publications Sage CA: Thousand Oaks, CA, v. 3, n. 4, p. 355--377, 2004.

CHANDRASEKARAN, S.; CHITHAMBARAM, T.; KHADER, S. A. Structural health monitoring of offshore structures using wireless sensor networking under operational and environmental variability. **International Journal of Environmental and Ecological Engineering**, v. 10, n. 1, p. 33--39, 2015.

CHEN, W.; NGUYEN, S. T.; COOPS, R.; OETOMO, S. B.; FEIJS, L. Wireless transmission design for health monitoring at neonatal intensive care units. In: **IEEE. 2009 2nd International Symposium on Applied Sciences in Biomedical and Communication Technologies**. [S.l.], 2009. p. 1--6.

ELETRONICWINGS. <https://www.electronicwings.com/raspberry-pi/mpu6050-accelerometergyroscope-interfacing-with-raspberry-pi>. Acessado em 15/03/2021.

FARRAR, C.; DOEBLING, S. Damage detection and evaluation ii: field applications to large structures. 1999.

FARRAR, C. R.; WORDEN, K. **Structural health monitoring: a machine learning perspective**. [S.l.]: John Wiley & Sons, 2012.

FERDOUSH, S.; LI, X. Wireless sensor network system design using raspberry pi and arduino for environmental monitoring applications. **Procedia Computer Science**, Elsevier, v. 34, p. 103--110, 2014.

FRANZONI, F.; SHIKI, S. B.; SILVA, S. da; JR, G. C. B. Identificação de um modelo dinâmico simplificado de uma unidade geradora usando análise de séries temporais. **Mecânica Computacional**, v. 29, n. 91, p. 8929--8946, 2010.

GALDINO, E.; CURY, A. Development of low-cost wireless accelerometer for structural dynamic monitoring. **Rev Interdiscip Pesqui Eng RIPE**, v. 2, p. 10--19, 2017.

GAO, R.; ZHANG, L. Micromachined microsensors for manufacturing. **IEEE Instrumentation Measurement Magazine**, v. 7, n. 2, p. 20--26, 2004. Disponível em: <<https://ieeexplore.ieee.org/document/1304562>>.

GIBNEY, E. 'open-hardware'pioneers push for low-cost lab kit. **Nature News**, v. 531, n. 7593, p. 147, 2016.

HAARMAN, M.; MULDER, M.; VASSILIADIS, C. Predictive maintenance 4.0: predict the unpredictable. **PwC and Mainnovation**, 2017.

HAMEED, Z.; HONG, Y.; CHO, Y.; AHN, S.; SONG, C. Condition monitoring and fault detection of wind turbines and related algorithms: A review. **Renewable and Sustainable energy reviews**, Elsevier, v. 13, n. 1, p. 1--39, 2009.

HUANG, Q.; TANG, B.; DENG, L. Development of high synchronous acquisition accuracy wireless sensor network for machine vibration monitoring. **Measurement**, Elsevier, v. 66, p. 35--44, 2015.

INMAN, D.; KHOSLA, R.; MAYFIELD, T. On-the-go active remote sensing for efficient crop nitrogen management. **Sensor Review**, Emerald Group Publishing Limited, v. 25, n. 3, p. 209--214, 2005.

INMAN, D. J.; FARRAR, C. R.; JUNIOR, V. L.; JUNIOR, V. S. **Damage prognosis: for aerospace, civil and mechanical systems**. [S.l.]: John Wiley & Sons, 2005.

JUDY, J. W. Microelectromechanical systems (MEMS): fabrication, design and applications. **Smart Materials and Structures**, IOP Publishing, v. 10, n. 6, p. 1115--1134, 2001. Disponível em: <<https://iopscience.iop.org/article/10.1088/0964-1726/10/6/301>>.

KAVITHA, S.; DANIEL, R. J.; SUMANGALA, K. Design and analysis of mems comb drive capacitive accelerometer for shm and seismic applications. **Measurement**, Elsevier, v. 93, p. 327--339, 2016.

KIANGALA, K. S.; WANG, Z. Initiating predictive maintenance for a conveyor motor in a bottling plant using industry 4.0 concepts. **The International Journal of Advanced Manufacturing Technology**, Springer, v. 97, n. 9, p. 3251--3271, 2018.

LIAO, Y.; KIREMIDJIAN, A. S.; RAJAGOPAL, R.; LOH, C.-H. Angular velocity-based structural damage detection. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. **Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems 2016**. [S.l.], 2016. v. 9803, p. 98031N.

LIU, Z.; YU, Y.; LIU, G.; WANG, J.; MAO, X. Design of a wireless measurement system based on wsns for large bridges. **Measurement**, Elsevier, v. 50, p. 324--330, 2014.

MAHMUD, M. A.; BATES, K.; WOOD, T.; ABDELGAWAD, A.; YELAMARTHI, K. A complete internet of things (iot) platform for structural health monitoring (shm). In: IEEE. **2018 IEEE 4th World Forum on Internet of Things (WF-IoT)**. [S.l.], 2018. p. 275--279.

MATTERN, F.; FLOERKEMEIER, C. From the internet of computers to the internet of things. In: **From active data management to event-based systems and more**. [S.l.]: Springer, 2010. p. 242--259.

NUNES, D. de S.; BRITO, J. L. V. de; DOZ, G. N. A Low-Cost Data Acquisition System for Dynamic Structural Identification. **IEEE Instrumentation and Measurement Magazine**, v. 22, p. 64 -- 72, 2019. Disponível em: <<https://ieeexplore.ieee.org/document/8868280>>.

SHIN, P. J. H. K. **Fundamentals of Signal Processing for Sound and Vibration Engineers**. John Wiley Sons, 2008. ISBN 9780470511886,0470511885. Disponível em: <<http://gen.lib.rus.ec/book/index.php?md5=c02818dbf7ecb7c05ec53a1fbf9db567>>.

SINGIRESU, S. R. et al. **Mechanical vibrations**. [S.l.]: Addison Wesley Boston, MA, 1995.

SOHN, S.; RIM, S.; LEE, I. Vibration measurement of wireless sensor nodes for structural health monitoring. **Advanced Science and Technology Letters**, v. 98, n. 1, 2015.

TOKOIGNON, C. A.; GAO, B.; TIAN, G. Y.; YAN, Y. Structural health monitoring framework based on internet of things: A survey. **IEEE Internet of Things Journal**, IEEE, v. 4, n. 3, p. 619--635, 2017.

TOLEDO, E.; CURY, A.; LANDRE, J. Assessment of low-cost wireless sensors for structural health monitoring applications. **Revista IBRACON de Estruturas e Materiais**, SciELO Brasil, v. 14, 2021.

VARANIS, M.; SILVA, A.; MERELES, A.; PEDERIVA, R. Mems accelerometers for mechanical vibrations analysis: A comprehensive review with applications. **Journal of the Brazilian Society of Mechanical Sciences and Engineering**, Springer, v. 40, n. 11, p. 1--18, 2018.

WORTMANN, F.; FLÜCHTER, K. Internet of things. **Business & Information Systems Engineering**, Springer, v. 57, n. 3, p. 221--224, 2015.

XIAOYAN, H.; KUANG, K. Structural motion monitoring systems using 9-axis sensing modules. In: **The 2016 structure congress (structures 16)**. [S.l.: s.n.], 2016.

YAMANOOR SRIHARI, N. S. High quality, low cost education with the raspberry pi. In: IEEE. **2017 IEEE Global Humanitarian Technology Conference (GHTC)**. [S.l.], 2017. p. 1--5.

ZONTA, T.; COSTA, C. A. da; RIGHI, R. da R.; LIMA, M. J. de; TRINDADE, E. S. da; LI, G. P. Predictive maintenance in the industry 4.0: A systematic literature review. **Computers & Industrial Engineering**, Elsevier, p. 106889, 2020.

Apêndice A - Código Python

```
1
2 '''
3     Read Gyro and Accelerometer by
4     Interfacing Raspberry Pi with MPU6050
5     using Python
6     http://www.electronicwings.com
7 '''
8
9 import smbus
10 #import SMBus module of I2C
11 import urllib.request
12 import time
13 import statistics
14 import numpy
15 from time import sleep
16
17 #some MPU6050 Registers and their Address
18 PWR_MGMT_1 = 0x6B
19 SMPLRT_DIV = 0x19
20 CONFIG = 0x1A
21 GYRO_CONFIG = 0x1B
22 INT_ENABLE = 0x38
23 ACCEL_XOUT_H = 0x3B
24 ACCEL_YOUT_H = 0x3D
25 ACCEL_ZOUT_H = 0x3F
26 GYRO_XOUT_H = 0x43
27 GYRO_YOUT_H = 0x45
28 GYRO_ZOUT_H = 0x47
29 TEMP_OUT_H = 0x41
30 myAPI = '1KLD0YC18383CJ83'
31 baseURL = 'https://api.thingspeak.com/update?api_key= % s' % myAPI
32
33 def MPU_Init():
34
35     #write to sample rate register
36     bus.write_byte_data(Device_Address,
```

```

37 SMPLRT_DIV, 7)
38 #Write to power management register
39 bus.write_byte_data(Device_Address,
40 PWR_MGMT_1, 1)
41 #Write to Configuration register
42 bus.write_byte_data(Device_Address,
43 CONFIG, 0)
44 #Write to Gyro configuration register
45 bus.write_byte_data(Device_Address,
46 GYRO_CONFIG, 24)
47 #Write to interrupt enable register
48 bus.write_byte_data(Device_Address,
49 INT_ENABLE, 1)
50
51 def read_raw_data(addr):
52     #Accelerometer and Gyro value are 16-bit
53     high =
54     bus.read_byte_data(Device_Address,
55     addr)
56     low =
57     bus.read_byte_data(Device_Address,
58     addr+1)
59     #concatenate higher and lower value
60     value = ((high << 8) | low)
61     #to get signed value from mpu6050
62     if(value > 32768):
63         value = value - 65536
64     return value
65
66 def peak_freq_calc(signal,Fs):
67     n1 = len(signal)
68     frq = numpy.arange(n1)/(n1/Fs)
69     frq = frq[range(int(n1/2))]
70     Y = numpy.fft.fft(signal)/n1
71     Y = Y[range(int(n1/2))]
72     Y[0]=0
73     indmax = numpy.where(abs(Y) == max(abs(Y)))
74     peakfreq = frq[indmax]
75     peakfreq = peakfreq[0]
76     return peakfreq
77
78 bus = smbus.SMBus(1) # or bus =
79 smbus.SMBus(0) for older version boards

```

```

80 Device_Address = 0x68      # MPU6050 device address
81
82 Fs = 200.0                  # Sampling frequency [Hz]
83 dt = 1/Fs                   # Sampling time [sec]
84 ns = 1000
85 nsc = 1000.0
86
87 sleeptime = 10
88
89 MPU_Init()
90 print ("Starting MPU6050 acquisition")
91
92 while True:
93     n=0
94     acc_x=numpy.zeros (ns)
95     acc_y=numpy.zeros (ns)
96     acc_z=numpy.zeros (ns)
97     T=numpy.zeros (ns)
98
99     while n<ns:
100         acc_x[n] =
101             read_raw_data (ACCEL_XOUT_H) /16384.0
102         acc_y[n] =
103             read_raw_data (ACCEL_YOUT_H) /16384.0
104         acc_z[n] = read_raw_data (ACCEL_ZOUT_H) /16384.0
105         T[n] = read_raw_data (TEMP_OUT_H) /340.0+35.0+1.35
106         n=n+1
107         sleep (dt)
108     acc_x = acc_x-numpy.mean (acc_x)
109     acc_y = acc_y-numpy.mean (acc_y)
110     acc_z = acc_z-numpy.mean (acc_z)
111     Ax = numpy.sqrt (numpy.sum (numpy.power (acc_x, 2)) /nsc)
112     Ay = numpy.sqrt (numpy.sum (numpy.power (acc_y, 2)) /nsc)
113     Az = numpy.sqrt (numpy.sum (numpy.power (acc_z, 2)) /nsc)
114
115     fx = peak_freq_calc (acc_x, Fs)
116     fy = peak_freq_calc (acc_y, Fs)
117     fz = peak_freq_calc (acc_z, Fs)
118
119     Tempcalc = numpy.mean (T)
120
121     conn = urllib.request.urlopen (baseURL + '&field1=%s&field2=%s&field3=%s
&field4=%s&field5=%s&field6=%s&field7=%s' % (Ax, Ay, Az, Tempcalc, fx,

```

```
fy, fz))
122 print(conn.read())
123 conn.close()
124
125 print ("\tAx=%.2f gRMS" %Ax, "\tAy=%.2f gRMS" %Ay, "\tAz=%.2f gRMS" %Az
, "\tT=%.2f C" %Tempcalc, "\tfx=%.2f Hz" %fx, "\tfy=%.2f Hz" %fy, "\tfz=%.2f
Hz" %fz)
126
127 sleep(sleeptime)
```