



**Programa de Pós-Graduação em Instrumentação, Controle e
Automação de Processos de Mineração (PROFICAM)
Escola de Minas, Universidade Federal de Ouro Preto (UFOP)
Associação Instituto Tecnológico Vale (ITV)**

Dissertação

**DESENVOLVIMENTO DE DISPOSITIVO AUTOMÁTICO DE MEDIÇÃO DE
UMIDADE DE MINÉRIO DE FERRO**

Matheus Teixeira Neiva

**Ouro Preto
Minas Gerais, Brasil
2022**

Matheus Teixeira Neiva

**DESENVOLVIMENTO DE DISPOSITIVO AUTOMÁTICO DE MEDIÇÃO DE
UMIDADE DE MINÉRIO DE FERRO**

Dissertação apresentada ao Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração da Universidade Federal de Ouro Preto e do Instituto Tecnológico Vale, como parte dos requisitos para obtenção do título de Mestre em Engenharia de Controle e Automação.

Orientador: Prof. Alan Kardek Rêgo Segundo, D.Sc.

Coorientador: Prof. Philip von Pritzelwitz, D. Sc.

Ouro Preto
2022

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

N417d Neiva, Matheus Teixeira.

Desenvolvimento de dispositivo automático de medição de umidade de minério de ferro. [manuscrito] / Matheus Teixeira Neiva. - 2022.
88 f.: il.: color., gráf..

Orientador: Prof. Dr. Alan Kardek Rego Segundo.

Coorientador: Dr. Philip Von Pritzelwitz.

Dissertação (Mestrado Profissional). Universidade Federal de Ouro Preto. Programa de Mestrado Profissional em Instrumentação, Controle e Automação de Processos de Mineração. Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração.

Área de Concentração: Engenharia de Controle e Automação de Processos Minerais.

1. Umidade. 2. Minérios de ferro. 3. Automação Industrial. I. Pritzelwitz, Philip Von. II. Segundo, Alan Kardek Rego. III. Universidade Federal de Ouro Preto. IV. Título.

CDU 681.5:622.2

Bibliotecário(a) Responsável: Maristela Sanches Lima Mesquita - CRB-1716



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE OURO PRETO
REITORIA
ESCOLA DE MINAS
PROGR. POS GRAD. PROF. INST. CONT. E AUT.
PROCESSOS DE MIN.



FOLHA DE APROVAÇÃO

Matheus Teixeira Neixa

Desenvolvimento de dispositivo automático de medição de umidade de minério de ferro

Dissertação apresentada ao Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração (PROFICAM), Convênio Universidade Federal de Ouro Preto/Associação Instituto Tecnológico Vale - UFOP/ITV, como requisito parcial para obtenção do título de Mestre em Engenharia de Controle e Automação na área de concentração em Instrumentação, Controle e Automação de Processos de Mineração

Aprovada em 05 de setembro de 2022

Membros da banca

Doutor - Alan Kardek Rêgo Segundo - Orientador - Universidade Federal de Ouro Preto

Doutor - Philip von Pritzelwitz - Instituto Tecnológico Vale

Doutora - Rosa Elvira Correa Pabón - Instituto Tecnológico Vale

Doutor - Eduardo Nunes Santos - Universidade Tecnológica Federal do Paraná

Alan Kardek Rêgo Segundo, orientador do trabalho, aprovou a versão final e autorizou seu depósito no Repositório Institucional da UFOP em 21/11/2022



Documento assinado eletronicamente por **Saul Emanuel Delabrida Silva, VICE-COORDENADOR(A) DE CURSO DE PÓS-GRADUAÇÃO EM INST. CONT. E AUTOMAÇÃO DE PROCESSOS DE MINERAÇÃO**, em 22/11/2022, às 15:33, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site

[http://sei.ufop.br/sei/controlador_externo.php?](http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0)

[acao=documento_conferir&id_orgao_acesso_externo=0](http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **0429477** e o código CRC **33B543E9**.

Referência: Caso responda este documento, indicar expressamente o Processo nº 23109.015676/2022-17

SEI nº 0429477

R. Diogo de Vasconcelos, 122, - Bairro Pilar Ouro Preto/MG, CEP 35402-163
Telefone: (31)3552-7352 - www.ufop.br

*Aos meus pais, que nunca mediram
esforços para que eu alcançasse os
meus objetivos.*

Agradecimentos

Agradeço a Deus por todas as bênçãos recebidas ao longo da minha vida. Aos meus pais, Maristania e Camilo, meu irmão, Vinícius, avós, tios e primos por todo o amor, apoio e incentivo na caminhada até aqui. Aos professores da UFOP/ITV, em especial aos meus orientadores Alan e Philip, por todo apoio, compreensão, parceria e conhecimentos transmitidos. À República Mansão Amarela, aos Milionários, Bilionários, Marcinha e agregados por me acolherem em Ouro Preto e me proporcionarem momentos incríveis nessa etapa da minha trajetória. Também aos amigos que cultivei em Ouro Preto e Ouro Branco, que contribuíram para deixar a caminhada mais gratificante, principalmente em um momento de pandemia. Aos amigos do PROFICAM e LABCAM, que me ajudaram na troca de conhecimento e apoio no desenvolvimento do trabalho. Aos amigos da Samarco, em especial ao time da Automação de Ubu, que me apoiaram nos momentos que precisei ficar ausente.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, Brasil (CAPES), Código de Financiamento 001; do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq); da Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG); e da Vale SA.

*“Faço o melhor, que sou capaz, só
pra viver em paz”
(Marcelo Camelo)*

Resumo

Resumo da Dissertação apresentada ao Programa de Pós Graduação em Instrumentação, Controle e Automação de Processos de Mineração como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

DESENVOLVIMENTO DE DISPOSITIVO AUTOMÁTICO DE MEDIÇÃO DE UMIDADE DE MINÉRIO DE FERRO

Matheus Teixeira Neiva

Setembro/2022

Orientadores: Alan Kardek Rêgo Segundo
Philip von Pritzelwitz

A umidade presente nos materiais é um parâmetro essencial para vários processos industriais. Na mineração, essa variável exerce muita influência em várias etapas da cadeia produtiva, como nos transportes ferroviário e marítimo, na pelletização e no armazenamento. Devido ao minério de ferro ser um produto com propriedades físicas variáveis, por causa da sua origem e dos diferentes tipos de processos produtivos, a medição dessa característica em específico é demasiadamente lenta e trabalhosa. Atualmente, a umidade é mensurada por meio de um método de pesagem e de secagem em estufa que demora mais de quatro horas para entregar o resultado de medição, o que acarreta em atrasos e retrabalhos ao longo da cadeia produtiva. De forma alternativa, existem métodos indiretos baseados na medição de propriedades elétricas dos materiais, que apresentam menor tempo de resposta. Nesse sentido, este trabalho tem como objetivo o desenvolvimento de um equipamento de bancada baseado na medição da impedância complexa e da densidade aparente do minério de ferro. Para tornar o procedimento de medição ainda mais rápido e mais padronizado, automatizou-se o equipamento por meio de sensores de posição e dispositivos eletromecânicos, reduzindo-se, assim, a interferência do operador. Além disso, avaliou-se o uso de técnicas de Inteligência Artificial na análise dos dados fornecidos pelo sistema. Testes realizados com uma versão manual do equipamento no Porto da Ponta da Madeira, São Luís, MA, apresentaram resultados muito promissores, visto que a incerteza de medição da umidade foi igual a 0,1578 pontos percentuais de umidade em base úmida, com um coeficiente de determinação de 98,41%, utilizando-se redes neurais artificiais. O equipamento automático, utilizando-se de regressão linear múltipla, apresentou uma incerteza de 0,71 pontos

percentuais de umidade em base úmida, com um coeficiente de determinação de 98%. Esses resultados demonstram o grande potencial da solução, mas também evidencia a necessidade de análises mais profundas com o equipamento automático, visto que não foi possível realizar análises com técnicas de inteligência artificial, devido a base de dados pequena.

Palavras-chave: Umidade, Minério de Ferro, Automação Industrial.

Macrotema: Logística; **Linha de Pesquisa:** Tecnologias da Informação, Comunicação e Automação Industrial; **Tema:** Redução de Umidade na Cadeia; **Área Relacionada da Vale:** Porto Ponta da Madeira, São Luís-MA.

Abstract

Abstract of Dissertation presented to the Graduate Program on Instrumentation, Control and Automation of Mining Process as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

DEVELOPMENT OF AN IRON ORE MOISTURE MEASUREMENT DEVICE

Matheus Teixeira Neiva

September/2022

Advisors: Alan Kardek Rêgo Segundo

Philip von Pritzelwitz

Moisture present in materials is an essential parameter for many industrial processes. In mining, this variable exerts a lot of influence on various stages of the production chain, such as rail and maritime transport, pelletizing and storage. Due to iron ore being a product with variable physical properties, because of its origin and the different types of production processes, the measurement of this specific characteristic is too slow and laborious. Currently, moisture is measured using a weighing method and drying in an oven that takes more than four hours to deliver the measurement result, which leads to delays and reworks along the production chain. Alternatively, there are indirect methods based on the measurement of electrical properties of materials, which have a shorter response time. In this sense, this work aims to develop a bench-top equipment based on the measurement of complex impedance and apparent density of iron ore. To make the measurement procedure even faster and more standardized, the equipment was automated using position sensors and electromechanical devices, thus reducing operator interference. In addition, the use of Artificial Intelligence techniques in the analysis of the data provided by the system was evaluated. Tests carried out with a manual version of the equipment in the Porto da Ponta da Madeira, São Luís, MA, showed very promising results, since the uncertainty of measurement of moisture was equal to 0.1578 percentage points of humidity on a wet basis, with a coefficient of determination of 98.41%, using artificial neural networks. The automatic equipment, using multiple linear regression, presented an uncertainty of 0.71 percentage points of humidity on a wet basis, with a coefficient of determination of 98%. These results demonstrate the great potential of the solution, but also evidence the need for deeper ana-

lyzes with the automatic equipment, since it was not possible to perform analyzes with artificial intelligence techniques, due to the small database.

Keywords: Moisture, Iron Ore, Industrial Automation.

Macrotheme: Logistics; **Research Line:** Industrial Information, Communication and Automation Technologies; **Theme:** Production Chain Moisture Reduction; **Related Area of Vale:** Ponta da Madeira Port, São Luís-MA.

Lista de Figuras

Figura 1.1	Linha do tempo da linha de pesquisa em unidade de minérios na UFOP/ITV.	17
Figura 2.1	Dispositivo de Medição Automático	20
Figura 2.2	Conjunto Célula de Carga	21
Figura 2.3	Conjunto Câmara de Medição	22
Figura 2.4	Conjunto de Compressão	23
Figura 2.5	Proteção/Estrutura	24
Figura 2.6	Resultado da análise do critério de falha de von Mises	25
Figura 2.7	Resultado da análise do deslocamento	26
Figura 2.8	Conjunto Calço	26
Figura 2.9	Equipamento automático construído.	27
Figura 2.10	(a) Placas paralelas carregadas opostamente; (b) capacitor ideal; (c) capacitor real	28
Figura 2.11	Método IV básico de medição de impedância complexa. (a): Princípio de funcionamento e (b): Variação da medição utilizando somente medição de tensão.	30
Figura 2.12	(a) Configuração base do método Conversor Corrente-Tensão IV com Amplificador de Transimpedância. (b) Circuito prático, considerando a impedância complexa como associação resistor-capacitor em paralelo.	31
Figura 2.13	Resposta em frequência do circuito da Figura 2.12(b) para valores conhecidos dos componentes. ($C_f = 10 \text{ pF}$, $G_f = 10 \text{ } \mu\text{S}$ ($100 \text{ k}\Omega$), C_x e G_x indicados na figura).	32
Figura 2.14	Diagrama esquemático do circuito eletrônico do sistema.	34
Figura 2.15	Fluxograma de execução da medição pelo equipamento automático.	35
Figura 3.1	Estrutura de um neurônio biológico	38
Figura 3.2	Estrutura de um neurônio artificial	38
Figura 3.3	Estrutura de uma RNA de múltiplas camadas típica	39
Figura 3.4	Desenho Esquemático (a) e equipamento manual (b) para medição de umidade de minério de ferro	41
Figura 3.5	Gráfico de alavancagem da regressão múltipla da primeira base de dados da máquina manual.	44

Figura 3.6 Gráfico de alavancagem da regressão múltipla da primeira base de dados da máquina manual removendo a densidade.	45
Figura 3.7 Gráfico de alavancagem da regressão múltipla da segunda base de dados da máquina manual.	46
Figura 3.8 Gráfico de caixas comparando os resultados de MSE normalizado para cada configuração da RNA	47
Figura 3.9 Histograma do resultado de MSE normalizado para a RNA com 10 neurônios na camada oculta	48
Figura 3.10 Previsão utilizando o modelo de RNA para toda a base de dados	49
Figura 3.11 Gráfico de erros para o modelo desenvolvido com RNA	49
Figura 3.12 Histograma dos erros do modelo desenvolvido com RNA	50
Figura 3.13 Gráfico de caixas comparando os resultados de MSE normalizado para cada configuração da RNA	51
Figura 3.14 Histograma do resultado de MSE normalizado para a RNA com 21 neurônios na camada oculta	52
Figura 3.15 Histograma do resultado de MSE normalizado para a RNA com 20 neurônios na camada oculta	53
Figura 3.16 Previsão utilizando o modelo de RNA para toda a base de dados	53
Figura 3.17 Gráfico de erros para o modelo desenvolvido com RNA	54
Figura 3.18 Histograma dos erros do modelo desenvolvido com RNA	54
Figura 3.19 Modelos de correção das saídas 1 (a) e 2 (b).	55
Figura 3.20 Capacitância do cabo em função do seu comprimento: com (a) e sem (b) aterramento da blindagem.	56
Figura 3.21 Ajuste fino da constante dielétrica relativa em relação ao ar e à água.	57
Figura 3.22 Ajuste fino da constante dielétrica relativa em relação ao ar e à água.	58
Figura 3.23 Gráfico de alavancagem da regressão múltipla da primeira base de dados da máquina automática.	60
Figura 3.24 Gráfico de alavancagem da regressão múltipla da primeira base de dados da máquina automática removendo o torque.	61
Figura 3.25 Gráfico de alavancagem da regressão múltipla da primeira base de dados da máquina automática, excluindo os dados com umidade abaixo de 7%.	62
Figura 3.26 Gráfico de alavancagem da regressão múltipla da segunda base de dados da máquina automática.	63

Lista de Tabelas

Tabela 3.1	Tabela de Coeficientes da Regressão Linear Múltipla da primeira base de dados da máquina manual.	43
Tabela 3.2	Tabela de Coeficientes da Regressão Linear Múltipla da primeira base de dados da máquina manual.	43
Tabela 3.3	Tabela de Coeficientes da Regressão Linear Múltipla da segunda base de dados da máquina manual.	45
Tabela 3.4	Tabela de Coeficientes da Regressão Linear Múltipla da primeira base de dados da máquina automática.	59
Tabela 3.5	Tabela de Coeficientes da Regressão Linear Múltipla da primeira base de dados da máquina automática, removido o torque.	59
Tabela 3.6	Tabela de Coeficientes da Regressão Linear Múltipla da primeira base de dados da máquina automática, excluindo os dados com umidade abaixo de 7%.	60
Tabela 3.7	Tabela de Coeficientes da Regressão Linear Múltipla da segunda base de dados da máquina automática.	62

Sumário

1	Introdução	15
1.1	Justificativa	17
1.2	Objetivos	18
1.3	Estrutura do Trabalho	19
2	Desenvolvimento Mecatrônico do Dispositivo	20
2.1	Conjunto Célula de Carga	20
2.2	Conjunto Câmara de Medição	21
2.3	Conjunto de Compressão	23
2.4	Proteção/Estrutura	24
2.5	Conjunto Calço	25
2.6	Eletrônica Embarcada	27
2.6.1	Propriedades Elétricas	27
2.6.2	Conversor Corrente-Tensão IV com Amplificador de Transimpedância	30
2.6.3	Circuito de Medição	33
3	Identificação do modelo de umidade	36
3.1	Regressão Linear	36
3.1.1	Regressão Linear Simples	36
3.1.2	Regressão Linear Múltipla	37
3.2	Inteligência Computacional	37
3.2.1	Redes Neurais Artificiais	37
3.3	Construção e análise das bases de dados	40
3.3.1	Equipamento Manual	40
3.3.2	Equipamento Automático	52
4	Conclusão	64
5	Trabalhos Futuros	66
	Referências Bibliográficas	67

1 Introdução

A umidade presente em diversos materiais é um parâmetro essencial para vários processos. Na agricultura, a umidade se fez importante no ar e no solo. Uma umidade alta no ar pode ocasionar dificuldade de transpiração na cultura, enquanto uma baixa umidade do solo, pode ocasionar em dificuldade de absorção de água e nutrientes pelas raízes (CUNHA *et al.*, 1992).

No processo de mineração, a umidade também tem muita influência em diversas etapas da cadeia produtiva. Um dos principais efeitos da umidade no minério de ferro se dá no custo de transporte. A umidade média do minério carregado pela Vale em seus portos é de 9,5% em base úmida. Em um navio Valemax, por exemplo, o qual tem capacidade para 400 toneladas, esse percentual representa aproximadamente 36 toneladas de água transportadas, impactando nos custos do seguro de transporte, além do próprio custo de transporte (VALE, 2020). Além disso, para que um navio de carga de minério possa sair do porto de origem, é necessário que a umidade do minério esteja abaixo do “Limite de Umidade Transportável” (TML - *Transportable Moisture Limit*), o qual é calculado individualmente para cada material em cada carregamento (VALE, 2020). Valores acima deste limite oferecem o risco de liquefação do material transportado, podendo ocasionar no adernamento da embarcação. Durante o carregamento, caso o minério apresente umidade acima do TML, o processo é suspenso, ocasionando em diversas perdas com estocagem, atrasos e diversos outros custos (PINTO *et al.*, 2017).

Devido ao minério de ferro ser um produto com propriedades físicas variáveis, por causa da sua origem e dos diferentes tipos de processos produtivos aos quais foi submetido, a medição dessa característica em específico é lenta e trabalhosa. O método mais confiável, e normatizado, utilizado por todo setor mineral atualmente é por meio de secagem e pesagem, denominado método padrão de estufa (ISO 3087:2020, 2020). Esse método consiste em pesar uma amostra de minério antes e depois de submetê-la a um processo de secagem em estufa com temperatura controlada, durante tempo suficiente para se obter a massa de minério seco. A diferença de peso, antes e depois da secagem, dividida pelo peso inicial da amostra representa a umidade do minério em base úmida.

O problema consiste no tempo necessário para se obter o resultado, que está atualmente em um mínimo de 4 horas (ISO 3087:2020, 2020). Essa demora na medição potencializa os impactos causados pela falta de controle de umidade nos processos de mineração, visto que o tempo de resposta para interromper o problema é muito alto. Além disso, em tempos chuvosos, não é possível ter confiança nos dados, devido aos altos índices pluviométricos, principalmente nos portos da região norte/nordeste do país.

Este trabalho é fruto de uma continuidade de uma linha de pesquisa que surgiu no âmbito da parceria entre a UFOP e o ITV. Ela surgiu a partir de um sistema de irrigação proposto por Rêgo Segundo (2014), o qual utiliza um método de medição de impedância complexa do solo, um meio poroso, por meio de um circuito conversor tensão-corrente (I-V) com amplificação de transimpedância.

A partir do trabalho desenvolvido por [Rêgo Segundo \(2014\)](#), [Lage \(2018\)](#) desenvolveu um sensor para medir a impedância complexa de uma amostra de minério de ferro e, por meio de regressão linear, estimar a sua umidade. A obtenção do modelo é realizada tomando-se como referência a umidade obtida pelo método padrão de estufa. Também neste mesmo trabalho, foi percebido por [Lage \(2018\)](#) que o modelo sofria forte influência da variação da densidade aparente da amostra. Isso ocorria devido aos espaços vazios presentes na mesma, os quais variavam junto com a densidade. Para contornar este desafio, [Lage \(2018\)](#) desenvolveu um primeiro protótipo que realizava a compressão da amostra a fim de padronizar a densidade aparente.

Após o desenvolvimento de [Lage \(2018\)](#), a linha de pesquisa se ramificou em quatro vertentes: medições de umidade em silos, em correias transportadoras, em vagões e em bancada. A primeira vertente foi proposta por [Silva \(2019\)](#), que desenvolveu um sensor capacitivo coplanar, o qual estaria posicionado na parede de um silo e forneceria a umidade em tempo real. A segunda vertente foi desenvolvida por [Pinto \(2019\)](#), que adaptou o sensor capacitivo de [Lage \(2018\)](#) em um carro de dois graus de liberdade para que este posicionasse o sensor na correia transportadora e acompanhasse seu movimento, realizando a medição da umidade por amostragem automática. A terceira linha foi proposta por [Santos \(2020\)](#), que desenvolveu um sensor capacitivo matricial para a medição do gradiente de umidade em um vagão de trem em escala reduzida. A quarta e última linha é a continuidade do trabalho original de [Lage \(2018\)](#), que [Rêgo Segundo et al. \(2019\)](#) adicionou um torquímetro para proporcionar uma padronização da força de compressão e melhorou toda a parte conceitual mecânica do conjunto. Toda essa linha do tempo pode ser vista na Figura [1.1](#).

A partir do trabalho de [Rêgo Segundo et al. \(2019\)](#), foi desenvolvido neste trabalho uma evolução mecatrônica do dispositivo, automatizando todo o processo, eliminando-se variações provenientes do erro humano. Também neste trabalho é verificada a viabilidade do uso de inteligência computacional na regressão do modelo de umidade do minério.

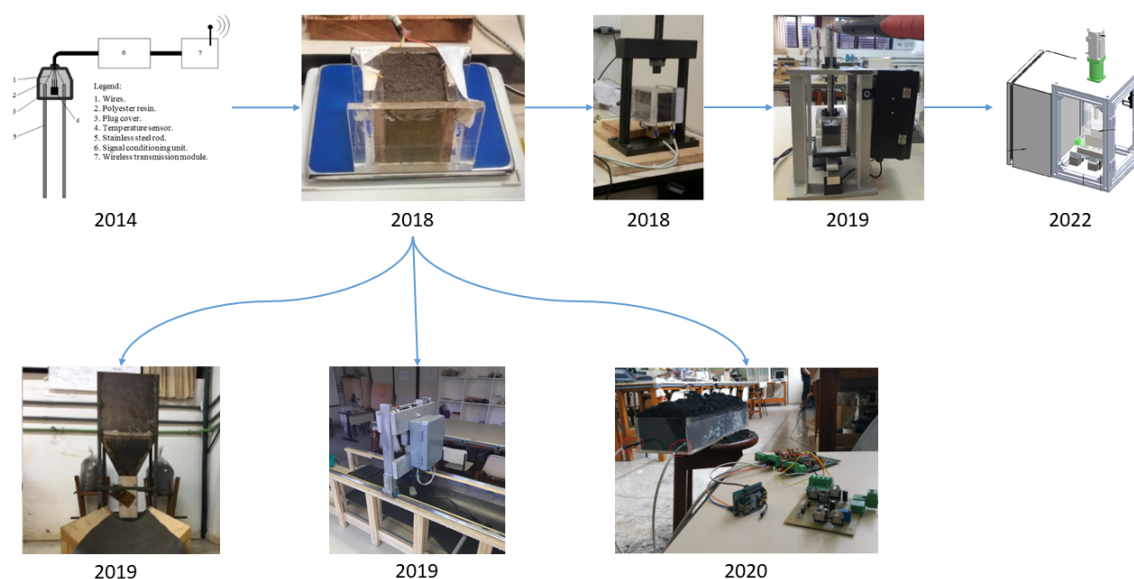


Figura 1.1: Linha do tempo da linha de pesquisa em umidade de minérios na UFOP/ITV.
Fonte: O Autor

1.1 Justificativa

A água está presente em praticamente toda a cadeia produtiva mineral, desde a umidade natural da rocha extraída até as chuvas e os processos de beneficiamento e transporte. Devido a isso, a umidade é um fator que precisa ser controlado em todas as etapas da cadeia de mineração, da mina ao porto, visto que essa parcela de água presente no minério não tem nenhum valor comercial, mas em algumas etapas, faz-se extremamente influente.

O controle preciso da umidade do minério é um forte requisito principalmente nas etapas de transporte e armazenamento. Nestas etapas, o desequilíbrio da umidade pode causar problemas nos custos de produção, de segurança e danos ao meio ambiente. Como exemplo, tem-se que o excesso de umidade reduz a eficiência do transporte e o torna ineficaz, devido à água ocupar uma porcentagem da carga que poderia ser ocupada por minério. Em contraponto a isso, a umidade não pode ser muito baixa, pois provoca alta emissão de partículas de minério pela ação do vento, podendo ocasionar em sanções relacionadas à legislação ambiental, conforme disposto no Art. 54 da Lei 9.605, de 12 de fevereiro de 1998 (BRASIL, 1998). Nos pátios, a umidade fora de padrões especificados, além do problema de emissão de particulados, pode gerar instabilidade em pilhas de minério e, conseqüentemente, causar acidentes. No transporte marítimo, o qual, de acordo com Ferreira *et al.* (2017), transporta milhões de toneladas de minério de ferro anualmente, além do problema de eficiência, ainda há o risco de adernamento das embarcações. Isto ocorre devido à liquefação do minério nos compartimentos destas, alterando seu centro de massa e instabilizando-as.

O fenômeno de liquefação ocorre quando um material sólido granular passa a se com-

portar como um material líquido devido ao aumento da poropressão da água e à redução da tensão efetiva. O Código Marítimo Internacional para Cargas Sólidas a Granel (IMSBC - *International Maritime Solid Bulk Cargoes Code*), principal legislação internacional que rege a segurança do transporte de cargas sólidas a granel a bordo de navios (inclusive minérios), define que granéis sólidos susceptíveis a liquefação são cargas compostas por uma certa proporção de sólidos finos e umidade capazes de liquefazer-se caso embarcados com umidade acima do TML. O TML é a umidade máxima considerada segura para o transporte marítimo de cargas a granel. A legislação internacional demanda que a umidade da carga seja mantida inferior ao TML durante o carregamento e transporte, a fim de prevenir a liquefação durante a operação.

Para realizar a medição da umidade, a principal técnica é o método gravimétrico (padrão de estufa), mas, apesar da elevada exatidão, é uma técnica muito trabalhosa e com tempo de resposta muito elevado, o que compromete o controle dos processos e a tomada de decisões preventivas (ÁVILA, 2010). Existem no mercado outras abordagens para entregar uma medição de umidade e em tempo real já utilizadas na mineração, como a medição por micro-ondas, mas estas necessitam de investimento elevado, devido ao custo do equipamento e a nacionalização da tecnologia (ÁVILA, 2010). Além disso, há a necessidade de importação de mão de obra especializada para calibração e manutenção dos equipamentos, mas que ainda assim não atingem a acurácia exigida nos processos de mineração (PINTO *et al.*, 2021).

Diante de todos os pontos apresentados, neste trabalho propõe-se o desenvolvimento de um dispositivo para a medição de umidade de minérios de forma automatizada, baseado no pedido de patente apresentado por Rêgo Segundo *et al.* (2019).

1.2 Objetivos

O objetivo geral deste trabalho é desenvolver um dispositivo automático de bancada para a medição de umidade de minérios no porto da Ponta da Madeira em São Luís-MA.

Os objetivos específicos compreendem:

1. Projetar a estrutura mecânica do equipamento;
2. Dimensionar sensores e atuadores do equipamento;
3. Projetar e aperfeiçoar circuitos elétricos e eletrônicos para controlar equipamentos e realizar medição de umidade;
4. Avaliar técnicas de regressão para a obtenção de modelos de umidade de minérios de ferro;
5. Comparar equipamentos manual e automático.

1.3 Estrutura do Trabalho

O capítulo 1 apresenta a introdução com a definição da área de estudo e os objetivos a serem perseguidos no desenvolvimento do presente trabalho. O capítulo 2 apresenta o desenvolvimento mecatrônico do equipamento, detalhando dispositivos mecânicos, técnicas de projeto, sensores e atuadores dimensionados. O capítulo 3 detalha todo o desenvolvimento das técnicas para a regressão dos modelos de umidade de minério de ferro. O capítulo 4 apresenta a conclusão do trabalho e o capítulo 5 as perspectivas para trabalhos futuros.

2 Desenvolvimento Mecatrônico do Dispositivo




Figura 2.1: Dispositivo de Medição Automático

Fonte: O Autor

O dispositivo de medição, que pode ser visto na Figura [2.1](#), foi concebido para condicionar alguns parâmetros da amostra, a fim de reduzir a variabilidade da medição. Para isso, é necessário eliminar os espaços vazios da amostra e mensurar sua densidade aparente. Logo, o dispositivo foi estruturado como um pequena prensa elétrica de bancada, que além de aplicar diferentes forças de compressão, realiza a medição da massa e da altura da amostra.

Para facilitar o desenvolvimento e entendimento acerca do dispositivo, este foi dividido em cinco conjuntos, os quais são detalhados neste capítulo. No Apêndice A pode ser visto os desenhos dos conjuntos na íntegra.

2.1 Conjunto Célula de Carga

O Conjunto Célula de Carga, visualizado na Figura [2.2](#), tem o objetivo de conferir ao dispositivo a habilidade de aferir a massa da amostra. Ele é constituído basicamente por uma célula de carga (1) modelo PWZL-2F de 5 kg e condicionador de sinais Incon LC 4200, pelo suporte da câmara de medição (2) e um conector elétrico. Esse conjunto foi dimensionado considerando que a amostra terá de 0,5 a 1 kg, com uma caixa de dimensões adequadas para esta quantidade de minério. A célula escolhida foi a do tipo *single-point*, devido ao baixo custo, ampla utilização em sistemas de pesagem, alta precisão e pela possibilidade de montagem com apoio de um calço durante a compressão do material, a fim de não a danificar.




Figura 2.2: Conjunto Célula de Carga

Fonte: O Autor

O suporte da câmara de medição foi dimensionado considerando a fixação disponível na célula de carga, dimensões da câmara de medição, facilidade de se inserir e remover a câmara para realizar a troca de amostras e desgaste do material. Para isso, foi utilizado o aço ABNT 8640 temperado e revenido para uma dureza de 48-52 HRC. Com este material e tratamento térmico, reduz-se o desgaste físico, devido à alta dureza e o desgaste químico, visto que a liga 8640 apresenta cromo e níquel em sua composição. Este aço também apresenta alta usinabilidade, facilitando a fabricação da peça.

O conector do conjunto serve para conectar facilmente os eletrodos de medição da caixa ao circuito de medição. Foi escolhido o blocos de terminais plugáveis de duas posições da Phoenix Contact por ser um conector de encaixe rápido, revestido de prata. Isso confere alta flexibilidade a conexão e baixo nível de ruído.

2.2 Conjunto Câmara de Medição

O Conjunto Câmara de Medição, visto na Figura [2.3](#), tem como objetivo de fornecer um ambiente para o condicionamento da amostra e constitui o elemento sensor das propriedades elétricas da amostra. É constituído por uma caixa em acrílico (1), dois eletrodos em aço inox (2) colados nas laterais internas da caixa em acrílico, uma placa de circuito impresso e um conector do tipo *header*.

A Câmara de Medição foi dimensionada para que comportasse uma massa de 0,5 a 1 kg de minério de ferro em seu interior, permitisse a visualização do conteúdo, possibilitasse o posicionamento de dois eletrodos planos paralelos, não influenciasse no campo elétrico dos




Figura 2.3: Conjunto Câmara de Medição
Fonte: O Autor

eletrodos e fosse de fácil inserção e remoção do equipamento. Para isso, foi escolhido o material polimérico acrílico, devido a excelente transparência, resistência, usinabilidade e isolamento elétrico. Foi projetada com uma parede mínima de 12 mm de espessura e em corpo único para garantir a integridade durante a compressão do material, considerado o uso de fresa de usinagem de 2 mm para facilitar a fabricação. Além disso, foram deixados entalhes para o posicionamento dos eletrodos, conector do tipo *Block Header* de duas posições e uma placa de circuito impresso, a qual realiza a ligação elétrica entre eletrodos e conector.

Os eletrodos foram desenvolvidos em chapa de aço inox 316L de 1 mm de espessura cortada por eletroerosão a fio, a fim de garantir as tolerâncias dimensionais do elemento sensor. Isto faz-se necessário para garantir a reprodutibilidade do coeficiente geométrico do elemento sensor, reduzindo-se a variação deste na calibração do sensor. O aço inox 316L foi escolhido devido a sua resistência a corrosão e abrasão, considerando que os eletrodos estão em contato com a amostra, além de apresentar características elétricas satisfatórias.

O conector escolhido foi o par do conector do Conjunto Célula de Carga, também fabricado pela Phoenix Contact, possuindo as mesmas características de encaixe rápido e revestido de prata, garantindo a flexibilidade da conexão e o baixo nível de ruído.

Para a conexão elétrica entre o conector e os eletrodos, foi escolhido uma placa de circuito impresso de fibra de vidro dupla face (FR4) de 1,6 mm de espessura, devido a boa resistência mecânica, baixo custo, facilidade da montagem do conjunto, repetibilidade das características elétricas e facilidade de fabricação.




Figura 2.4: Conjunto de Compressão
Fonte: O Autor

2.3 Conjunto de Compressão

O Conjunto de Compressão, visto na Figura 2.4, é o sistema mais complexo deste dispositivo, mas mesmo assim atua por um princípio simples. Basicamente funciona pelo princípio de um fuso (3) que transforma um movimento rotacional em um movimento linear. Essa transformação permite que um motor elétrico (6) seja utilizado para empurrar um punção (1) de encontro com a amostra a ser comprimida. Normalmente em prensas com fuso, a castanha (2) fica posicionada na estrutura fixa da prensa, enquanto o punção fica preso na extremidade inferior do fuso que, com sua rotação na castanha fixa, movimenta-se para cima ou para baixo.

Para que um motor elétrico seja adicionado para fazer a rotação do fuso nesta configuração, este deveria ser posicionado de um modo que acompanhasse o movimento ascendente/descendente do fuso e punção, ampliando a complexidade da solução consideravelmente e adicionando um grande número de elementos suscetíveis a desgaste e manutenção. Para contornar este complicador, o modelo foi ligeiramente alterado, de modo que a castanha fique posicionada no punção e o fuso fique fixo juntamente com o motor na estrutura da prensa. Deste modo, não se adiciona componentes novos além do motor para eletrificar a solução, somente há uma mudança

de perspectiva de qual elemento se movimenta e qual fica fixo no dispositivo.

Devido ao formato do punção acompanhar o formato da caixa, ele precisa manter uma orientação definida para que encaixe na caixa. Para que isso ocorra, faz-se necessário que o giro do punção com o giro do fuso seja anulado. Com isso, foi adicionado um sistema anti-giro composto por um rolamento linear (7) fixado no punção e um eixo retificado fixo à estrutura do dispositivo.

O motor elétrico selecionado para esta aplicação foi um servomotor Delta ECMA-C20604, o qual possui um torque nominal de 1,27 Nm e potência nominal de 400 W. Este servomotor oferece o controle de posição, por meio de um *encoder* rotativo, e torque precisos, possibilitando mensurar o torque aplicado na amostra e o deslocamento do punção.

O fuso selecionado foi o laminado de 20 mm de diâmetro e 5 mm de passo, com erro máximo de posicionamento de 0,05 mm/315 mm. Devido a estas especificações, foi necessário adicionar um redutor planetário WPF60 (5) com redução de 12:1 para que a força de compressão necessária fosse atingida. Para acoplar o fuso ao eixo do redutor planetário, foi selecionado um acoplamento de precisão da R+W (4) que garante a precisão na transmissão do movimento, reduzindo o erro de medição da posição pelo encoder.

2.4 Proteção/Estrutura




Figura 2.5: Proteção/Estrutura

Fonte: O Autor

A estrutura do dispositivo, visualizada na Figura [2.5](#), foi projetada também como proteção

física a acessos aos mecanismos internos da máquina conforme normatizado na Norma Regulamentadora 12. Foi utilizado no projeto perfis de alumínio estrutural (1, 2, 3 e 6) devido a facilidade construtiva, disponibilidade no mercado e resistência mecânica. As colunas e vigas com função estrutural foram dimensionadas com perfis 30x30 mm (1,2 e 3) e para a construção da porta de acesso foram utilizados perfis 20x20 mm (6). Para o topo e base (8 e 9), foram utilizados chapas de alumínio 6082-T6 de 15 mm de espessura.

Para avaliar a integridade da estrutura dimensionada, a força de tração que a prensa exerce na estrutura foi avaliada por meio da ferramenta de análise estática do Solidworks. Considerando o torque T máximo do motor com redutor planetário e raio l do fuso de esferas, além de considerar o rendimento em 100% tanto do redutor quanto do fuso de esferas, obtém-se que a força F de compressão da amostra e tração da estrutura, por meio da equação $F = \frac{T \cdot 2 \cdot \pi}{l}$, é igual a 7979,65 N.




Figura 2.6: Resultado da análise do critério de falha de von Mises
Fonte: O Autor

A força calculada foi arredondada para 8 kN e aplicada na estrutura concentrada no apoio do redutor planetário e com direcional realizando uma tração da estrutura. Na Figura 2.6 é possível perceber que a estrutura continuará íntegra, visto que a simulação do critério de falha de von Mises mostra que a tensão máxima de von Mises $1,11 \times 10^8 \text{ N/m}^2$ é menor que a tensão normal de escoamento do material $2,28 \times 10^8 \text{ N/m}^2$ e utilizando um fator de segurança mínimo de 2, ainda assim o critério é respeitado.

Também foi avaliada o deslocamento resultante da aplicação da força, o qual resultou em um deslocamento máximo de 0,3992 mm, que pode ser visto na Figura 2.7.

2.5 Conjunto Calço

Conforme dito anteriormente, a compressão da amostra se dá em cima da célula de carga e caso esta não seja protegida, a deformação a danificará. Para prevenir esta condição,




Figura 2.7: Resultado da análise do deslocamento
Fonte: O Autor




Figura 2.8: Conjunto Calço
Fonte: O Autor

foi dimensionado um calço mecânico (5), que pode ser visto na Figura [2.8](#), para suportar a compressão e proteger a célula de carga. Este calço é posicionado por meio de uma guia linear (1) em conjunto com um motor de passo (3) e um fuso (4). Este motor em conjunto com o fuso proporciona o movimento linear e a guia fornece a precisão no posicionamento. O calço foi projetado também em aço 8640 temperado e revenido pelos mesmos motivos das outras peças confeccionadas neste material. Na Figura [2.9](#), é possível visualizar o equipamento automático construído.




Figura 2.9: Equipamento automático construído.
Fonte: O Autor

2.6 Eletrônica Embarcada

2.6.1 Propriedades Elétricas

Campo Elétrico

De acordo com Boylestad (2012) e Resnick e Halliday (2009), campo elétrico é uma grandeza que define vetorialmente o módulo da força elétrica exercida por cada unidade de carga. Esta definição se dá pela distribuição de vetores em uma região. Normalmente é representado por linhas de campo, as quais indicam a intensidade do campo em torno de um corpo carregado.

Toda a ideia de linhas de campo surgiu com a lei de Gauss e foi aprimorada por Michael Faraday. Basicamente, quanto maior a carga, em Coulombs [C], maior a densidade de linhas de

campo por unidade de área.

O físico francês Charles Coulomb desenvolveu a lei da Física que leva o seu nome, determinando a força eletrostática resultante da interação entre duas cargas pontuais situadas no espaço com uma distância r . Na Equação 2.1 é possível visualizar a lei de Coulomb,

$$|F| = k_e \frac{|Q_1 Q_2|}{r^2}, \quad (2.1)$$

em que F é a força resultante [N], k_e é a constante eletrostática do vácuo [$=9 \times 10^9 \text{ Nm}^2/\text{C}^2$], Q_1 e Q_2 as cargas no espaço [C] e r a distância [m] (BOYLESTAD, 2012).

Capacitância

Considerando cargas não mais pontuais, mas sim planos infinitos paralelos, carregados com polos opostos e considerando que a magnitude de um campo elétrico é dada pela densidade de linhas de campo que atravessam uma superfície perpendicularmente, tem-se que o campo elétrico entre estas placas é uniforme. Mas caso considerado que estas placas sejam finitas, como no mundo real, um efeito de borda, que deforma o campo elétrico, surge, como pode ser visto na Figura 2.10 (RESNICK e HALLIDAY, 2009).




Figura 2.10: (a) Placas paralelas carregadas opostamente; (b) capacitor ideal; (c) capacitor real
Fonte: Silva (2019)

O efeito de borda é ignorado na maioria das aplicações práticas devido a área das placas normalmente ser muito maior que a distância entre elas, o que torna o campo uniforme ser muito mais significativo que o não-uniforme (BOYLESTAD, 2012).

Devido às placas estarem polarizadas com cargas opostas, estas cargas tendem a se acumular nas faces internas das placas, devido à lei de Coulomb. Visto esse fenômeno, é possível armazenar cargas elétricas em um sistema de placas paralelas, isoladas por um material dielétrico (não condutor), antagônico às características condutivas das placas. Esse sistema é denominado capacitor (RESNICK e HALLIDAY, 2009).

Segundo Boylestad (2012), para mensurar a capacidade de armazenamento de cargas de um capacitor quando submetido a uma diferença de potencial, é utilizada a grandeza capa-

capacitância, que é dada por

$$C = \frac{Q}{V}, \quad (2.2)$$

em que C é a capacitância [F], Q a carga [C] e V a tensão [V].

Também é possível descrever o conceito de capacitância relacionando-a com a geometria do capacitor, sendo dada por

$$C = \frac{A}{d} \epsilon_a, \quad (2.3)$$

em que A é a área da placa congruente [m^2], d a distância entre as placas [m] e ϵ a constante dielétrica [F/m], sendo esta que relaciona o material dielétrico com a capacitância.

O “material” de menor constante dielétrica é o vácuo, o qual também serve de referência para os outros materiais, visto que é possível multiplicar a constante dielétrica do vácuo (ϵ_0) por um valor que representa a razão entre a constante dielétrica absoluta do material (ϵ_a) e ϵ_0 , valor denominado de constante dielétrica relativa (ϵ'), adimensional.

Portanto, reescrevendo a Equação 2.3, é possível obter

$$C = k_g \epsilon_0 \epsilon', \quad (2.4)$$

em que k_g é a constante geométrica do capacitor [m], definida pela razão entre a área da placa congruente e a distância entre as placas.

Impedância

A impedância elétrica mede a oposição que um circuito elétrico oferece à passagem de corrente elétrica quando excitado por uma diferença de potencial elétrico. É expressa por um número complexo, como pode ser visto na Equação 2.5:

$$\dot{Z} = R + jX, \quad (2.5)$$

em que \dot{Z} é a impedância, R a resistência e X a reatância [Ω], sendo a resistência a parte que representa as perdas de energia por calor (Efeito Joule) e a reatância a parte da oposição que representa a troca de energia. A impedância também pode ser descrita pela primeira lei de Ohm, representada na Equação 2.6,

$$\dot{Z} = \frac{\dot{V}}{\dot{I}}, \quad (2.6)$$

em que \dot{V} é o fasor de tensão [V] e \dot{I} é o fasor de corrente [A] (BOYLESTAD, 2012).

Os elementos básicos de circuitos elétricos que apresentam características resistivas são os resistores e reativas os capacitores e indutores. Os indutores apresentam uma reatância positiva, enquanto os capacitores apresentam uma reatância negativa. As Equações 2.7 e 2.8 mostram o cálculo das reatâncias indutivas e capacitivas, respectivamente,

$$X_L = \omega L, \quad (2.7)$$

$$X_C = \frac{1}{\omega C}, \quad (2.8)$$

em que X_L é a reatância indutiva [Ω], L é a indutância [H], X_L a reatância capacitiva [Ω] (RESNICK e HALLIDAY, 2009).

Portanto, a impedância capacitiva é inversamente proporcional à frequência de excitação do circuito, podendo ser reescrita substituindo na Equação 2.8 a Equação 2.4, obtendo-se assim a Equação 2.9

$$X_C = \frac{1}{\omega k_g \epsilon_0 \epsilon'}, \quad (2.9)$$

a qual permite relacionar a reatância capacitiva com o material dielétrico.

Relacionando as Equações 2.5 e 2.9 com a segunda lei de Ohm, obtém-se

$$\dot{Z} = \rho \frac{1}{k_g} + j \frac{1}{\omega k_g \epsilon_0 \epsilon'}, \quad (2.10)$$

em que ρ é a resistividade elétrica [$\Omega.m$].

Escrevendo em termos de admitância, que é o inverso da impedância, obtém-se

$$\dot{Y} = \frac{1}{\dot{Z}} = k_g(\sigma + j\omega\epsilon_0\epsilon'). \quad (2.11)$$

2.6.2 Conversor Corrente-Tensão IV com Amplificador de Transimpedância

O meio mais simples e direto de se mensurar a impedância de um circuito é aplicando a própria definição de impedância, vista na Equação 2.5. Isto se dá medindo a amplitude e fase da corrente e tensão em cima da carga que se quer conhecer a impedância (RÊGO SEGUNDO, 2014; SILVA, 2008). A Figura 2.11(a) mostra a aplicação dessa medição direta.




Figura 2.11: Método IV básico de medição de impedância complexa. (a): Princípio de funcionamento e (b): Variação da medição utilizando somente medição de tensão.

Fonte: Silva (2008)

Também é possível realizar a medição da impedância utilizando somente valores de tensão, medindo-as conforme a Figura 2.11(b). Matematicamente, utiliza-se a Equação 2.12, em que \dot{V}_1 e \dot{V}_2 são fasores de tensão. Para qualquer uma das duas configurações, faz-se necessário que o valor de R seja precisamente conhecido e pequeno se comparado a \dot{Z}_x .

$$\dot{Z}_x = \left(\frac{\dot{V}_1}{\dot{V}_2 - \dot{V}_1} \right) R \quad (2.12)$$

A medição direta apresenta uma maior facilidade para a realização dos cálculos matemáticos para se encontrar a impedância complexa, mas tem baixa precisão, é difícil de se implementar devido a necessidade de medição de fase e apresenta uma alta sensibilidade para capacitâncias parasitas ligadas ao terra, encontradas normalmente nos cabos de ligação das sondas de medição (RÊGO SEGUNDO, 2014; SILVA, 2008).

Para contornar estas dificuldades, um amplificador de transimpedância é adicionado ao circuito, de modo que suas características de alta impedância de entrada e baixa impedância de saída possibilitem a medição de pequenas impedâncias entre eletrodos mesmo com altas impedâncias parasitas (RÊGO SEGUNDO, 2014; SILVA, 2008). O circuito base pode ser visto na Figura 2.12(a). Esse circuito apresenta um sinal AC de excitação \dot{V}_i , uma impedância desconhecida a ser mensurada \dot{Z}_x , uma impedância conhecida no ramo de realimentação \dot{Z}_f e um sinal de saída \dot{V}_o . Quando o circuito é excitado pelo sinal \dot{V}_i , a entrada inversora apresenta um potencial aterrado por um terra virtual formado pelo aterramento da entrada não-inversora e, devido a alta impedância de entrada, toda a corrente que passa por \dot{Z}_x deve necessariamente passar por \dot{Z}_f . Com isso, para acontecer o balanceamento dessa corrente, o amplificador altera a sua saída \dot{V}_o de modo a compensar a corrente sobre \dot{Z}_f . O cálculo da impedância é modelado conforme a Equação 2.13, a qual pode ser escrita também em termos de admitância \dot{Y}_x e \dot{Y}_f .

$$\frac{\dot{V}_o}{\dot{V}_i} = -\frac{\dot{Z}_f}{\dot{Z}_x} = -\frac{\dot{Y}_x}{\dot{Y}_f} \quad (2.13)$$




Figura 2.12: (a) Configuração base do método Conversor Corrente-Tensão IV com Amplificador de Transimpedância. (b) Circuito prático, considerando a impedância complexa como associação resistor-capacitor em paralelo.

Fonte: Silva (2008)

Na prática, utiliza-se uma associação em paralelo de resistor e capacitor para representar as impedâncias \dot{Z}_f e \dot{Z}_x , nomeadas G_x , C_x , G_f e C_f , sendo essas respectivamente condutância desconhecida, capacitância desconhecida, condutância de referência e capacitância de referência. Também há capacitâncias parasitas provenientes das blindagens dos cabos, representadas por C_{s1} e C_{s2} , mas que podem ser desconsideradas inicialmente devido a C_{s1} estar

sendo alimentada diretamente por \dot{V}_i e C_{s2} estar virtualmente aterrada pela entrada inversora. Esse circuito pode ser visto na Figura 2.12(b). Com isso, pode-se alterar a Equação 2.13, substituindo \dot{Z}_f e \dot{Z}_x por G_f , C_f , G_x e C_x , dando origem a Equação 2.14, em que $\omega = 2\pi f$ e f é a frequência do sinal de excitação [Hz] (RÊGO SEGUNDO, 2014; SILVA, 2008).

$$\frac{\dot{V}_o}{\dot{V}_i} = - \left(\frac{G_x + j\omega C_x}{G_f + j\omega C_f} \right) \quad (2.14)$$

A determinação de C_x e G_x pode ser feita de três modos: medindo-se amplitude e fase em uma frequência, medindo-se partes real e imaginária de \dot{V}_o ou medindo-se duas amplitudes em diferentes frequências. Mesmo que matematicamente seja possível utilizar facilmente qualquer um dos três métodos, a complexidade do circuito para realizar a medição dos valores, e suas incertezas, é bem menor quando medido duas amplitudes em diferentes frequências (RÊGO SEGUNDO, 2014; SILVA, 2008).

Quando se utiliza esse método de avaliar em duas frequências em magnitudes diferentes, tem-se que o ganho A é igual ao módulo de \dot{V}_o por \dot{V}_i , relacionando a entrada e a saída do circuito. Essa relação pode ser aplicada na Equação 2.14, obtendo

$$A = \left| \frac{\dot{V}_o}{\dot{V}_i} \right| = \left| \frac{\dot{Y}_x}{\dot{Y}_f} \right| = \frac{\sqrt{G_x^2 + (2\pi f)^2 C_x^2}}{\sqrt{G_f^2 + (2\pi f)^2 C_f^2}}. \quad (2.15)$$

Variando-se a frequência na Equação 2.15, para um mesmo valor para G_f e C_f , além de considerar valores conhecidos de C_x e G_x , obtém-se um gráfico da resposta em frequência para cada combinação de C_x e G_x . Esse gráfico pode ser visto na Figura 2.13.




Figura 2.13: Resposta em frequência do circuito da Figura 2.12(b) para valores conhecidos dos componentes. ($C_f = 10$ pF, $G_f = 10$ μ S (100 k Ω), C_x e G_x indicados na figura).

Fonte: Silva (2008)

Pode ser visto que existem dois platôs claros na Figura 2.13. Escolhendo-se uma frequência em cada um dos platôs para excitar o circuito, é possível aplicar os limites $f \rightarrow 0$ e $f \rightarrow \infty$ na Equação 2.15 e obter a magnitude de cada platô independentemente e relacioná-los com C_x e G_x . Mas, de acordo com Segundo et al. (2019), esta aproximação tem a limitação de não

mensurar independentemente os efeitos da condutância e capacitância quando o material a ser testado apresenta alta condutividade, devido à frequência do sinal do circuito não ser alta o suficiente para atingir o segundo platô (KEYSIGHT TECHNOLOGIES, 2017; RÊGO SEGUNDO, 2014; SILVA, 2008).

Para contornar este problema, Segundo *et al.* (2019) propôs um método denominado por ele *Real-dual-frequency*, o qual leva em consideração os valores reais das frequências de excitação aplicadas no circuito. Com isso, é possível obter os valores de condutividade (σ) e constante dielétrica (ϵ') manipulando as Equações 2.11 e 2.15, dando origem as Equações 2.16 e 2.17:

$$\sigma = \frac{1}{k_g} \sqrt{\frac{A_1^2 \omega_0^2 (G_f^2 + \omega_1^2 C_f^2) - A_0^2 \omega_1^2 (G_f^2 + \omega_0^2 C_f^2)}{(\omega_0^2 - \omega_1^2)}} \quad (2.16)$$

$$\epsilon' = \frac{1}{\epsilon_0 k_g} \sqrt{\frac{A_0^2 (G_f^2 + \omega_0^2 C_f^2) - A_1^2 (G_f^2 + \omega_1^2 C_f^2)}{(\omega_0^2 - \omega_1^2)}} \quad (2.17)$$

2.6.3 Circuito de Medição

O princípio de funcionamento do circuito de medição do sistema deste trabalho é baseado no circuito conversor I-V com amplificador de transimpedância, detalhado na Seção 2.6.2, e como parte de um sistema embarcado, desenvolvido em arquitetura 8 bits. Esse método possui alta precisão, resposta rápida e confiável devido ao amplificador operacional de transimpedância, que possui uma alta relação sinal ruído e é capaz de medir pequenas impedâncias (SEGUNDO *et al.*, 2015, 2017, 2018, 2019).

O diagrama esquemático do circuito eletrônico do sistema pode ser observado na Figura 2.14. Um microcontrolador PIC 18F25K80 é usado para mensurar as características elétricas do material na câmara de medição. Esse circuito integrado fornece os sinais de excitação do circuito de medição de impedância, realiza a aquisição dos sinais e processa os dados. Para isso, dois sinais PWM são gerados: um de 500 kHz e outro de 8 MHz, ambos com 50% do ciclo de trabalho. Esses sinais, após uma etapa de filtragem para torná-los aproximadamente senoidais, são utilizados para excitar os eletrodos da câmara de medição (tensão V_i). Os sinais V_o e V_i , tanto para o sinal de 500 kHz quanto para o sinal de 8 MHz, são mensurados pela mesma porta ADC do microcontrolador. Esses sinais passam primeiro por um multiplexador que seleciona qual sinal será lido e, em seguida, por um retificador de precisão e um filtro passa-baixa para, finalmente, serem processados pelo microcontrolador. A partir de uma interface UART, esse microcontrolador comunica com um Arduino Mega, que realiza a função de controlar o dispositivo. Esse elemento foi escolhido devido ao número suficiente de entradas e saídas digitais e à facilidade de integração com o servomotor, o motor de passo e a célula de carga.

Para realizar o controle do dispositivo, o Arduino Mega também se comunica via Modbus RTU e I/Os com o servodriver Delta para comandar e monitorar a compactação da amostra,

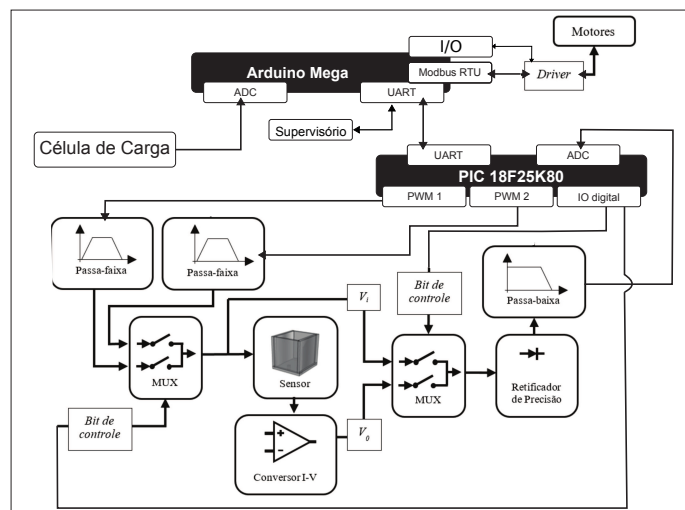


Figura 2.14: Diagrama esquemático do circuito eletrônico do sistema.
 Fonte: Adaptado de [Pinto \(2019\)](#)

adquirindo os dados de torque aplicado e deslocamento do fuso. O Arduino também controla o motor de passo que posiciona o calço antes da compactação por meio de interface de I/O digital. Além disso, a leitura da célula de carga se dá por meio do conversor ADS1230, o qual se comunica com o Arduino Mega por meio da interface SPI. Para realizar a medição, o Arduino recebe um comando do supervisor via interface UART, realiza a pesagem da amostra, avança o calço, realiza as compressões e adquire os dados do servo, recua o punção, recua o calço e envia os dados de medição para o supervisor. Na Figura [2.15](#), é possível visualizar o fluxo de execução da medição, realizado pelo equipamento automático.

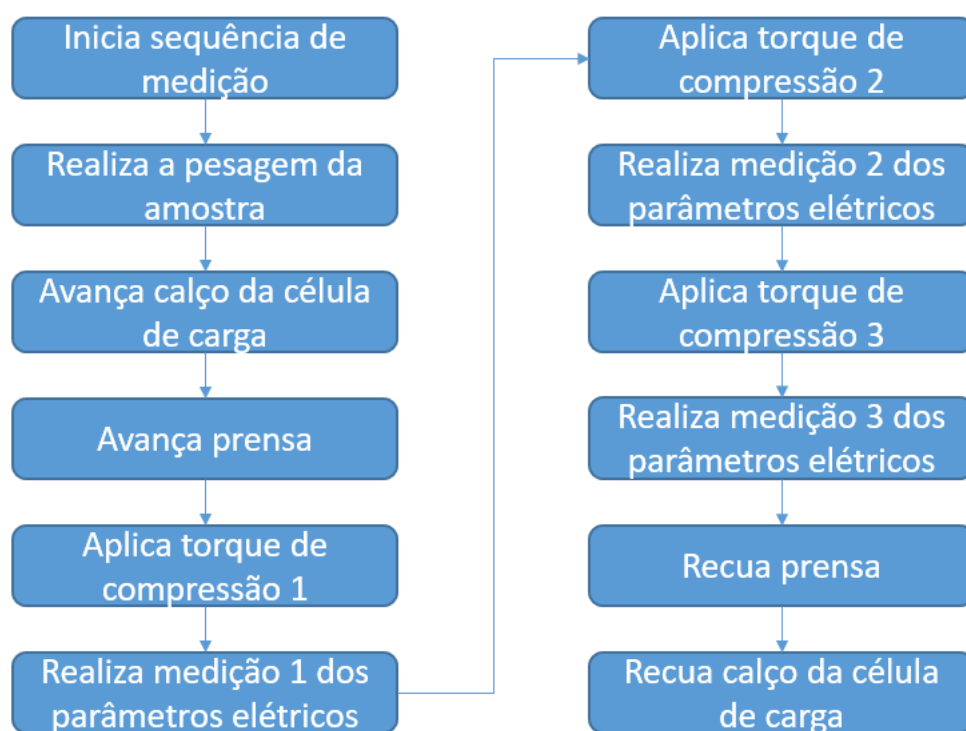


Figura 2.15: Fluxograma de execução da medição pelo equipamento automático.

Fonte: O Autor

3 Identificação do modelo de umidade

A identificação do modelo de umidade se baseou nos seguintes parâmetros: condutividade e constante dielétrica da amostra, torque de compactação, densidade aparente e altura da amostra. Essas variáveis foram escolhidas devido a sua disponibilidade e facilidade de medição, além da necessidade de diminuir a variabilidade entre as medições, aumentando a exatidão dos resultados.

Uma das técnicas utilizadas para obtenção dos modelos foi a Regressão Linear Múltipla, ferramenta análoga a regressão linear simples, mas para o caso em que a variável dependente pode depender de mais de um fator independente. A outra técnica utilizada foi a Rede Neural Artificial, que permite a identificação de sistemas multivariáveis com boa precisão e fácil implementação, além de conseguir excelentes resultados mesmo utilizando uma base de dados ruidosa. A sua desvantagem se deve da dependência de bases de dados grandes o suficiente para que o treinamento seja efetivo para mitigar os ruídos e potencializar a generalização (BRAGA *et al.*, 2007).

3.1 Regressão Linear

Uma regressão linear é descrita como uma equação para se estimar o valor de uma variável Y (condicional) por meio de valores de outras variáveis x (explicativa). É chamada de linear por considerar na construção da equação que é linear a relação da resposta às variáveis.

3.1.1 Regressão Linear Simples

Na regressão linear simples, os coeficientes da equação são os coeficientes da equação de uma reta com um erro associado

$$E(Y|x) = \beta_0 + \beta_1 x + \varepsilon, \quad (3.1)$$

em que $E(Y|x)$ é o valor esperado de Y para um dado valor de x , β_0 é o valor que y assume quando x é zero, β_1 é o coeficiente que determina a força de correlação entre as variáveis e ε é o erro associado.

Para se encontrar os valores estimados de β_0 e β_1 , normalmente se utiliza o Método dos Mínimos Quadrados. Este método é um estimador que minimiza a soma dos quadrados dos resíduos da regressão para maximizar o grau de ajuste do modelo aos dados observados. Por se tratarem de estimativas, convém alterar a notação para b_0 , b_1 e e , obtendo:

$$y_i = b_0 + b_1 x_i + e_i, \quad (3.2)$$

em que y_i é o valor observado de Y , b_0 é o valor estimado que y assume quando x é zero, b_1 é o coeficiente estimado que determina a força de correlação entre as variáveis e e_i é o resíduo da

observação, sendo i a indicação de cada uma das n observações.

Com isso, pode-se encontrar os valores de b_0 e b_1 pelas equações:

$$b_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{(x_i - \bar{x})^2} \quad (3.3)$$

$$b_0 = \bar{y} - b_1 \bar{x}, \quad (3.4)$$

em que \bar{x} é a média amostral de x e \bar{y} é a média amostral de y .

3.1.2 Regressão Linear Múltipla

A regressão linear múltipla é uma extrapolação da regressão simples, em que as variáveis explicativas podem ser mais de uma, mas o método de estimação dos coeficientes continua sendo a minimização da soma do quadrado dos resíduos. A equação que rege a regressão linear múltipla é definida como:

$$y_i = b_0 + b_1 x_{i1} + b_2 x_{i2} + \dots + b_p x_{ip} + e_i, \quad (3.5)$$

em que b_p são os coeficientes estimados que determinam a força de correlação entre as variáveis, p a indicação para as n variáveis e e_i é o resíduo da observação, sendo i a indicação de cada uma das n observações.

Para a aplicação do método de regressão linear múltipla, foi utilizada a função *fitlm* do MATLAB.

3.2 Inteligência Computacional

De acordo com o Conselho de Redes Neurais do IEEE de 1996, Inteligência Artificial (IA) é o estudo sobre como fazer computadores fazerem as coisas que as pessoas já fazem, melhor. A Inteligência Computacional (IC) é o estudo de mecanismos adaptativos facilitadores de comportamentos inteligentes em ambientes complexos e de constante mudança. Estes mecanismos incluem paradigmas de IA que exibem uma habilidade de aprender ou adaptar-se a novas situações, de generalizar, abstrair, descobrir e associar. Um dos paradigmas da IC são as Redes Neurais Artificiais (RNA) (ENGELBRECHT, 2007).

3.2.1 Redes Neurais Artificiais

As RNAs, como o nome já indica, são estruturas baseadas nos arranjos neurais dos neurônios biológicos (NB). Surgiram devido a tentativa de fazer um algoritmo computacional modelar e adquirir as habilidades cerebrais, como aprender, memorizar e generalizar. Na Figura

3.1 é possível visualizar a estrutura de um neurônio biológico (BRAGA *et al.*, 2007; ENGELBRECHT, 2007; YU e WILAMOWSKI, 2018).




Figura 3.1: Estrutura de um neurônio biológico
Fonte: Engelbrecht (2007)

O NB é composto basicamente por um corpo celular, dendritos e axônio. Ele se comunica com outro NB disparando uma sinapse (sinal elétrico) do seu axônio para os dendritos de outro e esses dendritos inibem ou amplificam os sinais recebidos. O neurônio artificial (NA) imita essa estrutura com entradas que inibem ou amplificam sinais capturados por meio de pesos numéricos associados a cada conexão de entrada do neurônio, coleta e computa esses sinais como uma função dos sinais de entrada e seus respectivos pesos e fornece um sinal de saída (BRAGA *et al.*, 2007; ENGELBRECHT, 2007; YU e WILAMOWSKI, 2018). Uma representação da estrutura de um NA pode ser vista na Figura 3.2.




Figura 3.2: Estrutura de um neurônio artificial
Fonte: Engelbrecht (2007)

Uma RNA é constituída por camadas de NAs. Necessariamente, uma RNA deve ter uma camada de entrada, camadas ocultas e uma camada de saída e os NAs de uma camada são conectados a outros neurônios da camada seguinte. Também podem apresentar conexões de *feedback* para camadas anteriores (BRAGA *et al.*, 2007; ENGELBRECHT, 2007; YU e WILAMOWSKI, 2018).

Existem diferentes tipos de topologias de RNAs, sendo as mais utilizadas as do tipo *Feedforward* (FFNN) e estes tipos são utilizados para diversas finalidades, como diagnóstico de

doenças, reconhecimento de fala, mineração de dados, processamento de imagens, previsão do tempo, análise de crédito, classificação, reconhecimento de padrões, regressões, como no caso deste trabalho, e diversos outros (BRAGA *et al.*, 2007; ENGELBRECHT, 2007; YU e WILAMOWSKI, 2018). Na Figura 3.3 pode-se visualizar a estrutura típica de uma rede FFNN de múltiplas camadas.




Figura 3.3: Estrutura de uma RNA de múltiplas camadas típica
Fonte: Braga *et al.* (2007)

Para se utilizar uma RNA como uma solução para um problema, faz-se necessário primeiramente passar esta RNA por uma fase de aprendizagem, que é quando a rede extrai informações relevantes de um conjunto de padrões apresentados a ela, a fim de criar uma representação para o problema. Essa etapa consiste em um processo iterativo de ajuste dos pesos da RNA que guardam o conhecimento que a rede adquiriu durante o treinamento sobre o ambiente em que esta opera. Duas são as principais abordagens de aprendizado: o aprendizado não-supervisionado e o aprendizado supervisionado, sendo o último o mais utilizado (BRAGA *et al.*, 2007; ENGELBRECHT, 2007; YU e WILAMOWSKI, 2018).

No aprendizado supervisionado, as entradas e saídas desejadas são fornecidas pela rede por um agente externo, normalmente denominado supervisor ou professor. Esse aprendizado tem como objetivo ajustar os pesos da rede de forma que a rede encontre uma ligação entre um par de conjuntos de entradas e saídas. Para isso, o supervisor fornece à rede a cada iteração um conjunto de entradas, recebe desta uma saída, compara essa saída com a saída esperada e com o erro proveniente desta comparação, realiza-se o ajuste dos pesos para reduzir este erro. Assim que o erro atinge um valor mínimo estipulado no início do treinamento, encerra-se o aprendizado. Os algoritmos de treinamento mais famosos são a regra delta e sua generalização para redes de múltiplas camadas, o *backpropagation* (BRAGA *et al.*, 2007; ENGELBRECHT, 2007; YU e WILAMOWSKI, 2018).

O algoritmo de *backpropagation* pode ser utilizado em conjunto com algoritmos de otimização para reduzir o seu tempo de convergência e melhorar seu desempenho fugindo de mínimos locais da função objetivo. Um destes algoritmos é o algoritmo Levenberg-Marquadt. O algoritmo utiliza uma aproximação de uma matriz Hessiana, utilizando a matriz Jacobiana, visto que o cálculo de uma matriz Hessiana para RNAs do tipo *feedforward* é complexo e caro computacionalmente. Com isto, este algoritmo apresenta um desempenho superior e com resultado similar ao uso de métodos Newtonianos de otimização (BRAGA *et al.*, 2007; ENGELBRECHT, 2007; YU e WILAMOWSKI, 2018).

Redes de uma só camada (ou um só neurônio) somente conseguem resolver problemas linearmente separáveis. Para resolver problemas não-linearmente separáveis faz-se necessário o uso de redes de múltiplas camadas e de acordo com of Illinois at Urbana-Champaign. Center for Supercomputing Research *et al.* (1988), uma rede com uma camada intermediária consegue implementar qualquer função contínua e duas camadas permite aproximar qualquer função. As camadas intermediárias de uma RNA basicamente funcionam como um detector de características, gerando uma codificação interna, utilizada pela camada de saída da rede para definir este sinal (BRAGA *et al.*, 2007; ENGELBRECHT, 2007; YU e WILAMOWSKI, 2018).

O uso de duas ou mais camadas intermediárias facilita o treinamento, mas a utilização de um grande número de camadas reduz a precisão do erro propagado, visto que quem tem real noção sobre o erro cometido pela rede é a camada de saída. A definição da quantidade de neurônios nas camadas ocultas geralmente é definido empiricamente, mas um dos métodos propostos é definir em função do número de entradas e saídas (BRAGA *et al.*, 2007; ENGELBRECHT, 2007; YU e WILAMOWSKI, 2018).

3.3 Construção e análise das bases de dados

Para a construção das bases de dados necessárias para o desenvolvimento do trabalho, foi desenvolvido também uma versão manual do dispositivo de medição, anteriormente ao desenvolvimento da versão automática. A aquisição destes dados foi realizada em uma campanha de medições no Laboratório de Análises Físicas do Porto da Madeira em São Luís-MA. No Apêndice B é possível encontrar as bases de dados detalhadas.

3.3.1 Equipamento Manual

Os principais elementos do equipamento manual incluem: câmara de medição construída em acrílico, representada pelo número “1”, onde é inserida a amostra de minério; eletrodos de aço inoxidável, representados pelo número “2”; estrutura metálica de suporte do sistema de compressão representada pelo número “3”; placa de acrílico utilizada como superfície que permite a compressão da amostra, representada pelo número “4”; fuso roscado que permite o deslocamento vertical do sistema de compressão, conectado a uma chave dinamométrica digital

cuja finalidade é padronizar a força aplicada, representados pelo número “5”; célula de carga para medir o peso da amostra e determinar a densidade aparente, representada pelo número “6”; escala que permite medir a altura do minério e, conseqüentemente, o volume da amostra, também representado pelo número “5”; gaveta para encaixe de um bloco de suporte, evitando sobrecarga da célula de carga quando o processo de compressão do minério estiver em operação, representado pelo número “7”; e a caixa do circuito de medição, representada pelo número “8”. A Figura 3.4 (a) mostra o desenho esquemático, enquanto a Figura 3.4 (b) mostra o protótipo real usado na campanha de medição.

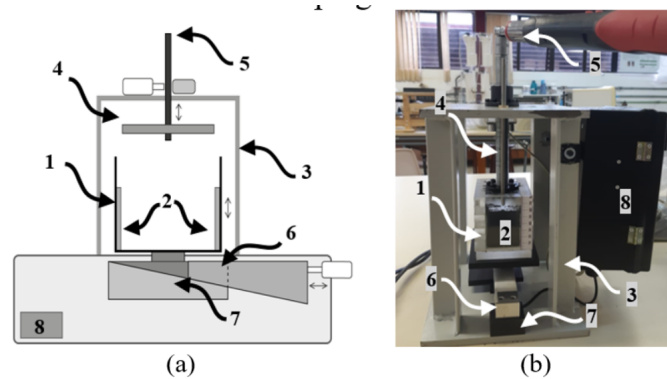


Figura 3.4: Desenho Esquemático (a) e equipamento manual (b) para medição de umidade de minério de ferro

Fonte: [Rêgo Segundo *et al.* \(2019\)](#)

O equipamento possui uma célula de medição de umidade com eletrodos de placas paralelas e meios para padronizar a compressão do minério com o objetivo de atingir densidades predeterminadas. Essa abordagem minimiza os efeitos que os espaços vazios têm sobre os sensores com base na medição da impedância do material proposta por [Rêgo Segundo *et al.* \(2019\)](#).

Procedimento de Calibração

Antes de usar o minério de ferro, o sistema de medição foi calibrado com substâncias que possuem constante dielétrica relativa e condutividade bem estabelecida. Foram utilizadas essas características como referência para determinar os modelos de calibração do sensor em relação à impedância complexa.

A constante dielétrica relativa de cada substância foi obtida utilizando dados da literatura. Além disso, foi utilizado um medidor de condutividade Del Lab do modelo DL-150P para determinar a condutividade elétrica. Assim, foram preparadas soluções contendo diferentes proporções de água destilada e álcool; e com diferentes concentrações de água e NaCl, para reproduzir amostras com diferentes constantes dielétricas relativas e condutividades elétricas, respectivamente ([LAGE, 2018](#); [PINTO *et al.*, 2021](#); [PINTO, 2019](#); [SANTOS, 2020](#); [SEGUNDO *et al.*, 2015, 2017, 2018, 2019](#)).

Cada uma dessas amostras foi inserida no sensor, uma de cada vez, e foram coletados os ganhos A_1 e A_2 , ambos para a frequência de excitação de 500 kHz e 8 MHz, respectivamente. Além disso, foi aplicado o método de *real-dual frequency* e, a partir daí, os resultados foram correlacionados com a condutividade e a constante dielétrica relativa das substâncias, por meio de uma regressão polinomial.

Aquisição e construção da primeira base de dados

O Laboratório de Análises Físicas do Porto da Madeira em São Luís-MA, forneceu as amostras utilizadas para estabelecer o banco de dados. Essas amostras representam uma parte do mesmo minério avaliada pelo laboratório de análises físicas e são utilizadas para determinar a umidade carregada no navio. Em outras palavras, a umidade utilizada como variável de saída da rede foi determinada e fornecida pelo laboratório de análises da Vale e estabelecida por meio de técnicas gravimétricas padronizadas pela [ISO 3087:2020](#) (2020).

O processo de medição com o minério de ferro começa quando a amostra do mineral é colocada na câmara de medição, uma célula de carga determina seu peso e o calço é posicionado na gaveta. Em seguida, são aplicados torques de 1,5 Nm, 1,7 Nm, 2 Nm, 5 Nm e 10 Nm, respectivamente, à amostra de minério e, para cada um deles, são armazenadas as seguintes variáveis para serem utilizadas como entradas da rede neural: torque aplicado, altura, densidade aparente, condutividade elétrica e constante dielétrica relativa da amostra. Torques superiores a estes danificavam a câmara de medição.

Para determinar o banco de dados de treinamento, validação e teste da rede, foram utilizadas 67 amostras de IOCJ. Cada um destas amostras foram submetidas a cinco níveis diferentes de compressão e torques entre 1,5 Nm e 10 Nm, totalizando 335 medições. A base de dados original tinha 554 medições, construída com 92 amostras, mas foram retiradas as medições com 0 Nm de torque, devido a variabilidade na deposição do material na câmara de medição; amostras com torque superior a 15 Nm, pois a câmara de medição foi danificada; amostras preparadas em laboratório; *outliers* de densidade; e amostras que foram comprimidas mais que 5 vezes. A umidade associada às amostras de minério avaliadas apresentou umidades entre 7% e 9,5%, considerando a base úmida. Estes valores que representam umidade comum para o período chuvoso e, portanto, representam grande parte da faixa de interesse de medição da empresa.

Construção da Segunda Base de Dados

A segunda base de dados foi construída utilizando-se dos dados da primeira base. Enquanto a primeira tinha como variáveis de entrada torque aplicado, altura, densidade aparente, condutividade elétrica e constante dielétrica relativa da amostra, com torques de 1,5 Nm, 1,7 Nm, 2 Nm, 5 Nm e 10 Nm, na segunda foram eliminados os torques abaixo de 2 Nm e agrupou-se cada amostra de umidade em uma mesma linha, eliminando-se assim a variável de torque aplicado. Com isso, a base de dados apresenta 60 observações com as variáveis de constante

dielétrica relativa da amostra, condutividade elétrica, altura e densidade aparente triplicadas, uma para cada valor de torque. Com isso, a base de dados apresenta doze variáveis de entrada e uma de saída, a umidade.

Análise da Primeira Base de Dados com Regressão Linear Múltipla

Para realizar a regressão linear múltipla, utilizou-se da ferramenta MATLAB. Também, para aplicar o método, foi realizada uma normalização dos dados, utilizando a função *normalize* do MATLAB, com uma média em zero e o desvio padrão em 1. Essa regressão obteve os coeficientes de acordo com a Tabela 3.1.

Tabela 3.1: Tabela de Coeficientes da Regressão Linear Múltipla da primeira base de dados da máquina manual.

Fonte: O Autor

	Coef. Estimados	SE	tStat	pValue
(Interseção)	$4,9191 \times 10^{-15}$	0,038254	$1,2859 \times 10^{-13}$	1
Torque	-0,33866	0,074249	-4,5611	$7,2112 \times 10^{-6}$
Altura	-0,29581	0,07026	-4,2103	$3,3028 \times 10^{-5}$
Densidade	-0,19404	0,12976	-1,4954	0,13578
Condutividade	0,94361	0,050972	18,513	$8,4958 \times 10^{-53}$
Const. Dielétrica	-0,31022	0,073204	-4,2378	$2,942 \times 10^{-5}$

Como também pode ser visto na Tabela 3.1, considerando um nível de confiança de 95%, a única variável que não se mostrou correlacionada com a saída de acordo com o teste estatístico t foi a densidade, com um p-value de 0,13578. Além disso, a raiz quadrada do erro médio (RMSE) ficou em 0,697, Erro Máximo Absoluto (MAE) em 0,2135% de umidade e coeficiente de determinação ajustado (\bar{R}^2) em 0,514. Além disso, esse modelo obteve uma incerteza de 0,58% de umidade. Na Figura 3.5 é demonstrado o gráfico de alavancagem dessa regressão, no qual é possível visualizar que a maioria dos pontos ficaram bem dispersos, o que se refletiu em um baixo coeficiente de determinação.

Eliminando a densidade do modelo, obtém-se os coeficientes de acordo com a Tabela 3.2.

Tabela 3.2: Tabela de Coeficientes da Regressão Linear Múltipla da primeira base de dados da máquina manual.

Fonte: O Autor

	Coef. Estimados	SE	tStat	pValue
(Interseção)	$4,4172 \times 10^{-15}$	0,038327	$1,1525 \times 10^{-13}$	1
Torque	-0,41771	0,052233	-7,997	$2,2243 \times 10^{-14}$
Altura	-0,22496	0,051977	-4,3281	$2,0018 \times 10^{-5}$
Condutividade	0,94314	0,051067	18,469	$1,1397 \times 10^{-52}$
Const. Dielétrica	-0,38663	0,052521	-7,3615	$1,4859 \times 10^{-12}$




Figura 3.5: Gráfico de alavancagem da regressão múltipla da primeira base de dados da máquina manual.

Fonte: O Autor

Esses coeficientes apresentam um RMSE em 0,698, MAE em 0,2128% de umidade e um \bar{R}^2 de 0,512. Além disso, esse modelo obteve uma incerteza de 0,5957% de umidade. Na Figura 3.6 é possível verificar que essa flutuação nos valores de RMSE, MAE e \bar{R}^2 não foram significativas.

Análise da Segunda Base de Dados com Regressão Linear Múltipla

Na regressão linear múltipla desenvolvida em cima da segunda base de dados, também foi realizada uma normalização dos dados, utilizando a função *normalize* do MATLAB, com uma média em zero e o desvio padrão em 1. Isso foi feito para melhor padronizar os dados e melhorar a efetividade da comparação. Essa regressão obteve os coeficientes de acordo com a Tabela 3.3.

Como também pode ser visto na Tabela 3.3, todas as variáveis se mostraram não correlacionadas com a saída, de acordo com o teste estatístico t, visto que apresentaram um p-value acima de 0,05. Mas mesmo assim, o RMSE ficou em 0,694, MAE em 0,1973% de umidade e \bar{R}^2 em 0,526. Além disso, esse modelo obteve uma incerteza de 0,5335% de umidade. Na Figura 3.7 é apresentado o gráfico de alavancagem dessa regressão, no qual é possível visualizar que muitos dos pontos ficaram bem dispersos, o que se refletiu em um baixo coeficiente de determinação. É também possível perceber que houve uma maior aproximação dos pontos da




Figura 3.6: Gráfico de alavancagem da regressão múltipla da primeira base de dados da máquina manual removendo a densidade.

Fonte: O Autor

Tabela 3.3: Tabela de Coeficientes da Regressão Linear Múltipla da segunda base de dados da máquina manual.

	Coef. Estimados	SE	tStat	pValue
(Interseção)	-0,0049171	0,089689	-0,054824	0,95651
Const. Dielétrica 1	1,8401	2,8423	0,64738	0,52054
Const. Dielétrica 2	-0,80112	3,5953	-0,22283	0,82464
Const. Dielétrica 3	-1,6442	3,3245	-0,49457	0,62321
Condutividade 1	0,55888	1,6	0,34931	0,72842
Condutividade 2	-0,12894	2,6549	-0,048568	0,96147
Condutividade 3	0,4749	2,4797	0,19151	0,84895
Altura 1	7,522	4,8954	1,5366	0,13111
Altura 2	-0,52178	0,93228	-0,55967	0,57836
Altura 3	-6,8781	4,8698	-1,4124	0,16442
Densidade 1	3,7526	3,2021	1,1719	0,24714
Densidade 2	-0,031542	0,1045	-0,30183	0,76411
Densidade 3	-3,5321	3,1589	-1,1181	0,26919

Fonte: O Autor

fronteira.

Comparando as análises das regressões lineares múltiplas para as duas bases de dados, é possível perceber que houve uma melhora no MAE da segunda base de dados. É possível também afirmar que o resultado não se mostrou satisfatório, devido ao \bar{R}^2 estar em patamares




Figura 3.7: Gráfico de alavancagem da regressão múltipla da segunda base de dados da máquina manual.

Fonte: O Autor

baixos. Isso pode estar relacionado a erros intrínsecos aos dados, os quais não podem ser contornados por um modelo linear. Esses erros podem ter origem na operação do equipamento manual, variabilidade do processo produtivo, visto que esses dados foram obtidos de amostras de carregamentos diferentes, entre outros.

Projeto da primeira RNA

O tipo de RNA escolhido para o projeto foi a FFNN com uma camada oculta, visto que a função a ser modelada não possui descontinuidades, e com arquitetura baseada em cinco variáveis de entrada: torque, altura do minério, densidade aparente, condutividade elétrica e constante dielétrica relativa; e uma variável de saída: umidade. Para realizar o treinamento da rede, utilizou-se a técnica de *backpropagation*, em conjunto com o algoritmo de Levenberg-Marquardt. Durante a implementação, os dados foram divididos aleatoriamente da seguinte forma: 70% do banco de dados para treinamento, 15% para teste e 15% para validação. Foi utilizada uma única camada intermediária e um algoritmo de varredura para definir o número ideal de neurônios entre 5 e 20, executando dez mil processos de treinamento e armazenando seus resultados para aplicar métodos estatísticos, utilizando o software estatístico R, para encontrar o número ideal. Depois disso, o algoritmo foi alterado para executar cem mil iterações de treinamento apenas com o número ideal de neurônios para encontrar a rede mais bem trei-

nada. Foram armazenados apenas os dados de treinamento das redes que apresentaram erro quadrático médio de validação (MSE - *Mean Squared Error*) inferior a 0,1 em escala normalizada. A função de ativação utilizada em cada um dos neurônios foi a sigmoideal, e o critério de parada de aprendizagem foi o MSE.

Após rodar o algoritmo de varredura, foi gerado um gráfico de caixas a fim de comparar as medianas e desvio padrão do MSE para os dados de validação à medida que o número de neurônios da camada oculta aumenta. Este gráfico pode ser visualizado na Figura 3.8.




Figura 3.8: Gráfico de caixas comparando os resultados de MSE normalizado para cada configuração da RNA

Fonte: O Autor

Conforme pode ser visto na Figura 3.8, a configuração que obteve o menor MSE foi a RNA com 10 neurônios na camada oculta, com um MAE mediano de 0,7672% de umidade, MSE mediano de 0,1837 e desvio padrão de 0,0600. Na Figura 3.9 pode ser visto um histograma do MSE da RNA com 10 neurônios.

Muito próximos desses resultados ficaram as redes de 9 e 11 neurônios, com um MAE mediano de 0,5845 e 0,5062% de umidade, MSE mediano de 0,1850 e 0,1859 e desvio padrão de 0,0612 e 0,0599, respectivamente. Com isso, foi realizado um teste de Wilcoxon para avaliar se as configurações são equivalentes. Para a configuração de 9 neurônios, houve correlação, com o teste apresentando um p-value de 0,1566. Já para a configuração de 11 neurônios, não houve correlação, com o p-value de 0,01743. Com isto, foi escolhida como melhor configuração 10 neurônios na camada oculta.

Após definida a melhor configuração, buscou-se a realizar os treinamentos para conseguir a melhor rede treinada. Para isso, foram realizados cem mil treinamentos da configuração de 10 neurônios. O melhor treinamento, considerando o treinamento que obteve o menor MSE global, apresentou um MSE de validação normalizado de 0,0598, MSE global normalizado de 0,0397, MAE global de 0,3288 pontos percentuais de umidade e um coeficiente de correlação global de 98,02%.




Figura 3.9: Histograma do resultado de MSE normalizado para a RNA com 10 neurônios na camada oculta

Fonte: O Autor

A Figura 3.10 mostra os resultados do modelo obtido pela RNA (linha azul) em comparação com os dados reais de umidade (linha laranja). Cada amostra em teste resulta em cinco medições de umidade, uma para cada torque aplicado. Para determinar a umidade medida pelo equipamento, foi feita uma média dessas cinco previsões.

A Figura 3.11 mostra o gráfico de erro comparando os resultados obtidos pela RNA prevista com a umidade real. O erro máximo foi de 0,1787 pontos percentuais, resultado que demonstra a capacidade preditiva de um sensor baseado em redes neurais e comprova que é possível atingir um nível de precisão e exatidão que permite a aderência do equipamento na cadeia de produção de minério.

A Figura 3.12 mostra um histograma de frequência dos erros do sistema. Com base nesses dados e considerando o nível de 95% de probabilidade, a incerteza do equipamento que utiliza redes neurais foi de 0,1662 pontos percentuais.




Figura 3.10: Previsão utilizando o modelo de RNA para toda a base de dados
Fonte: O Autor




Figura 3.11: Gráfico de erros para o modelo desenvolvido com RNA
Fonte: O Autor

Projeto da Segunda RNA

Para o projeto da segunda RNA, foram adotados os mesmos critérios e parâmetros de projeto da primeira RNA, exceto que o algoritmo de varredura procurou a melhor configuração entre 20 e 28 neurônios na camada oculta, além da arquitetura baseada em doze variáveis de




Figura 3.12: Histograma dos erros do modelo desenvolvido com RNA

Fonte: O Autor

entrada, detalhadas anteriormente.

Após rodar o algoritmo de varredura, foi gerado um gráfico de caixas a fim de comparar as medianas e desvio padrão do MSE para os dados de validação à medida que o número de neurônios da camada oculta aumenta. Este gráfico pode ser visualizado na Figura 3.13.

Conforme pode ser visto na Figura 3.13, a configuração que obteve o menor mediana do MSE foi a RNA com 21 neurônios na camada oculta, com uma mediana de 0,5939 e desvio padrão de 0,4316, além de um MAE mediano de 0,8337% de umidade, com desvio padrão de 0,2766. Na Figura 3.14 pode ser visto um histograma do MSE da RNA com 21 neurônios.

Muito próximos desses resultados ficou a rede de 20 neurônios, com um MSE mediano de 0,59567 e desvio padrão de 0,4388, além de um MAE mediano de 0,8363% de umidade, com desvio padrão de 0,2812. Com isso, foi realizado um teste de Wilcoxon para avaliar se as configurações são equivalentes. Para esta configuração, houve correlação, com o teste Wilcoxon apresentando um p-value de 0,6634. Com isto, foi escolhida como melhor configuração 20 neurônios na camada oculta, visto que requer menor processamento. Na Figura 3.15 pode ser visto o histograma do MSE da RNA com 20 neurônios.

Após definida a melhor configuração, buscou-se a realizar os treinamentos para conseguir a melhor rede treinada. Para isto, foram realizados cem mil treinamentos da configuração de 10 neurônios. O melhor treinamento, considerando o treinamento que obteve o menor MSE global, apresentou um MSE de validação de 0,0663, MSE global de 0,0330, MAE global de 0,3965 pontos percentuais de umidade e um coeficiente de correlação global de 98,41%. A Figura 3.16 mostra os resultados do modelo obtido pela RNA (linha azul) em comparação com




Figura 3.13: Gráfico de caixas comparando os resultados de MSE normalizado para cada configuração da RNA

Fonte: O Autor

os dados reais de umidade (linha laranja).

Já na Figura 3.17 é possível visualizar o gráfico de erro comparando os resultados obtidos pela RNA prevista com a umidade real.

A Figura 3.18 mostra um histograma de frequência dos erros do sistema. Com base nesses dados e considerando o nível de 95% de probabilidade, a incerteza do equipamento que utiliza redes neurais foi de 0,1578 pontos percentuais.

É possível perceber que com o uso de RNA para identificar os modelos de regressão das bases de dados, o desempenho se torna extremamente melhor. O coeficiente de correlação passou de 98% e com uma incerteza próxima de 0,15% de umidade em base úmida. Com a reorganização da base de dados também se obteve um menor incerteza em relação à primeira RNA. Essa expressiva melhora nos modelos se deve a não-linearidade da RNA, que por conta disso tem um grande poder de generalização e abstração de ruídos, eliminando as variações e tendências provocadas por erros sistêmicos e aleatórios.




Figura 3.14: Histograma do resultado de MSE normalizado para a RNA com 21 neurônios na camada oculta

Fonte: O Autor

3.3.2 Equipamento Automático

A partir do equipamento manual, desenvolveu-se o equipamento automático. Ele foi concebido para verificar se é possível aumentar a acurácia, minimizando a interferência do operador no processo de medição. Além disso, faz-se necessário minimizar o tempo de resposta e de possibilitar a integração com os sistemas de informação de plantas industriais.

Novo Procedimento de Calibração

Para o equipamento manual e em trabalhos anteriores (LAGE, 2018; PINTO *et al.*, 2021; RÊGO SEGUNDO *et al.*, 2019; SEGUNDO *et al.*, 2015), o sistema de medição era calibrado utilizando-se diferentes substâncias como referência (ar, água, álcool e misturas de água e álcool e de água e NaCl), o que torna o procedimento trabalhoso, principalmente se o sistema for replicado, pois há necessidade de repetir o processo de calibração para cada equipamento. Visando aumentar a escalabilidade do sistema, de modo que a calibração de um circuito eletrônico sirva para outros, propôs-se uma nova forma de calibração: utilizar pares de resistores e capacitores como referência ao invés das substâncias, ligados diretamente ao conector do circuito, sem cabo. Para isso, foram selecionados, de forma criteriosa, combinações de resistores e capacitores para reproduzirem pontos de calibração de condutividade e de constante dielétrica relativa




Figura 3.15: Histograma do resultado de MSE normalizado para a RNA com 20 neurônios na camada oculta

Fonte: O Autor




Figura 3.16: Previsão utilizando o modelo de RNA para toda a base de dados

Fonte: O Autor




Figura 3.17: Gráfico de erros para o modelo desenvolvido com RNA

Fonte: O Autor




Figura 3.18: Histograma dos erros do modelo desenvolvido com RNA

Fonte: O Autor

ao longo da faixa de medição desejada para o instrumento (σ em torno de 10 a 300 $\mu S/cm$ e ϵ de 1 a 80 para o teste inicial), considerando-se a constante geométrica do sensor igual a 0,13 m. Como os capacitores e resistores utilizados apresentam tolerância de fabricação de até 5%, seus valores foram determinados de forma mais acurada por meio de um analisador de impedância de 300 MHz, do fabricante Hioko. Todos os ensaios foram realizados em ambiente com temperatura controlada, a 20 °C.

Com base na modelagem do sensor (RÊGO SEGUNDO *et al.*, 2019), para os pontos de referência fornecidos pelos capacitores e resistores, obtém-se os modelos de correção das saídas do circuito, apresentados pela Figura 3.19. Vale a pena destacar que apenas um modelo de 1ª ordem foi suficiente para ajustar as saídas do circuito. As diferenças em relação à resposta teórica podem ser atribuídas à não idealidade dos componentes, das trilhas dos circuitos, do multiplexador e do circuito retificador. Em trabalhos anteriores este ajuste era feito por meio de um polinômio de 4 termos e utilizando-se substâncias para reproduzirem os pontos de calibração medidos pelo elemento sensor do sistema, o que, de certa forma, reduz a escalabilidade do sistema. Como a nova abordagem não utiliza o elemento sensor ligado à placa para realizar a sua calibração, e sim os pares de resistor e capacitor, espera-se que a mesma calibração de um circuito possa servir em outros. Esse procedimento desvincula a calibração do elemento sensor à calibração do circuito eletrônico. Logo, espera-se também que a mesma calibração de um circuito sirva para sensores com tamanhos de cabo e geometria diferentes. Foram utilizadas 84 combinações de resistores e capacitores, os quais tinham os valores 270, 390, 680, 1000, 3300 e 5600 Ω e 20 pF inicial, com passos de 10 pF, até 150 pF.




Figura 3.19: Modelos de correção das saídas 1 (a) e 2 (b).

Fonte: O Autor

Destaca-se que este novo procedimento facilita a escolha da impedância de referência para o circuito de medição. Para que o sensor seja capaz de medir ao longo da faixa de medição desejada, deve-se selecionar R_f e C_f em torno da metade da faixa de medição, levando-se em consideração o tamanho do cabo e a constante geométrica do sensor. Desta forma, evita-se que o sinal de saída do circuito sature (tanto atingindo o valor mínimo quanto máximo). Com isso, a faixa escolhida foi $R_f = 680 \Omega$ e $C_f = 100 \text{ pF}$;

O efeito do tamanho do cabo que liga o circuito de medição ao elemento sensor foi avaliado, utilizando-se um par de fios de um cabo manga de cinco vias AWG26. Os testes foram realizados após a calibração da placa de medição, com e sem aterramento da blindagem do cabo. Na Figura 3.20 apresenta-se o efeito da capacitância do cabo em função do seu comprimento.

Para fins de validação dessa nova proposta de calibração, utilizou-se um sensor de hastes




Figura 3.20: Capacitância do cabo em função do seu comprimento: com (a) e sem (b) aterramento da blindagem.

Fonte: O Autor

paralelas ($kg = 0,13$) com cabo de tamanho 0,93 m para realizar a medida da constante dielétrica do ar e da água. Além disso, como ϵ do ar é 1,0 e da água é 79,2 (a 20 °C), aproximadamente, propôs-se utilizar a primeira condição para estimar a capacitância do cabo por meio da seguinte relação analítica, baseada em teoria de circuitos:

$$C_b = C_w + C_s \rightarrow C_w = C_b - C_s = C_b - \epsilon_0 \epsilon_{ar} k_g \quad (3.6)$$

em que C_b é a capacitância medida pelo circuito de medição, C_w é a capacitância do cabo e C_s é capacitância do sensor. Como $\epsilon_{ar} = 1,0$, $\epsilon_0 = 8,854 pF/m$ (permissividade do vácuo) e $kg = 0,13$, obteve-se a capacitância do cabo igual a 33,17 pF, condizente com os resultados apresentados na Figura 3.20(a).

Eliminando-se o efeito da capacitância do cabo nas medições posteriores, e considerando a segunda condição (sensor na água), obtém-se um ajuste fino da medição da constante dielétrica relativa com base no ajuste de uma reta, que relaciona os pontos medidos e os valores de referência, dado pela seguinte expressão:

$$\epsilon_{ref} = a_1 \epsilon + b_1 \quad (3.7)$$

em que ϵ_{ref} é a constante dielétrica relativa de referência, ϵ a constante dielétrica relativa medida pelo sensor antes do ajuste, a_1 é o coeficiente angular e b_1 o coeficiente linear da reta. Os resultados do ajuste são apresentados na Figura 3.21, em que os valores de a e b podem ser facilmente obtidos por meio das propriedades da reta. A pequena diferença entre os valores medidos e a constante dielétrica de referência podem ser atribuídas à não idealidade da geometria do sensor considerada no cálculo de kg .

Essa nova abordagem permite memorizar os parâmetros do modelo de correção da saída do circuito, de capacitância do cabo e os parâmetros de ajuste da constante dielétrica relativa




Figura 3.21: Ajuste fino da constante dielétrica relativa em relação ao ar e à água.

Fonte: O Autor

na memória EEPROM do microcontrolador do circuito de medição, tornando o sistema mais escalável.

Um ensaio para avaliar o efeito da variação da temperatura do circuito eletrônico sobre as medidas foi realizado inserindo-se apenas o circuito eletrônico dentro de uma câmara climatizada e mantendo uma impedância fixa (capacitor e resistor) do lado de fora da câmara a temperatura constante de 20 °C, reproduzindo $\varepsilon = 63,97$ e $\sigma = 99,18 \mu S/cm$. A câmara foi ajustada para iniciar o ensaio a 5 °C, com passos de 5 °C até atingir 50 °C, permanecendo uma hora em cada temperatura e 30 min para realizar a transição. Na Figura 3.22 apresenta-se o resultado do ensaio, constatando que as medições são pouco influenciadas pela variação de temperatura do circuito, apresentando deriva térmica para ε de ± 602 ppm (partes por milhão) e para σ de ± 341 ppm. Apesar de os capacitores e resistores do novo circuito de medição apresentarem deriva térmica de ± 30 ppm e ± 50 ppm, respectivamente, o efeito total no circuito foi maior possivelmente devido à propagação dos efeitos em cada etapa de funcionamento (filtração, conversor I-V, multiplexação e retificação). No entanto, o erro máximo devido à variação da temperatura do circuito eletrônico permaneceu baixo tanto para ε quanto para σ , de $\pm 1,8$ e $\pm 1,6 \mu S/cm$, respectivamente, para uma faixa de temperatura de 2,05 °C até 49,57 °C.

Aquisição e construção da primeira base de dados

Para aquisição da base de dados da máquina automática, foi utilizado um minério ROM fornecido pelo ITV e pré-processado pela Fundação Gorceix, a qual realizou a cominuição e classificação do mesmo, padronizando-o em uma granulometria -50+100#. A composição química consistia em um percentual de ferro entre 67,92 e 68,00%, sílica entre 0,74 e 0,79%, alumina entre 0,10 e 0,13%, fósforo até 0,1% e óxido de titânio entre 0,01 e 0,02%. Além disso, todos os ensaios foram realizados em um ambiente climatizado a 20 °C.




Figura 3.22: Ajuste fino da constante dielétrica relativa em relação ao ar e à água.
Fonte: O Autor

Para a preparação das amostras, o minério foi secado em estufa de acordo com a [ISO 3087:2020](#) (2020) e quarteado em dezesseis amostras seguindo a ISO 3082. Foi utilizado o quarteador tipo Jones para realizar o quarteamento em amostras de 500 g cada. Após a etapa de quarteamento, foram calculadas e pesadas as massas de água necessárias para a formulação de amostras de 0 a 16% de umidade em base úmida. Após a pesagem, a água foi incorporada às amostras. Finalizada a preparação das amostras, iniciou-se a aquisição de dados com a máquina automática.

A amostra de minério foi inserida na câmara de medição e esta foi encaixada na base do equipamento. Uma célula de carga determinou seu peso e, utilizando um motor de passo, o calço foi posicionado na gaveta. Em seguida, foram aplicados torques de 0,61 Nm, 0,76 Nm e 0,91 Nm, respectivamente, à amostra de minério e, para cada um deles, também foram armazenadas as seguintes variáveis para serem utilizadas como entradas da rede neural: torque aplicado, altura, densidade aparente, condutividade elétrica e constante dielétrica relativa da amostra. Foi utilizado uma faixa de torque menor, devido ao receio de se danificar a câmara de medição antes de se conseguir uma base de dados para realizar as análises.

Após esses passos a base de dados foi obtida com 51 medições de 17 amostras com uma umidade variando de 0 a 16%.

Construção da Segunda Base de Dados

A segunda base de dados foi construída nos moldes da segunda base de dados da máquina manual, mas utilizando a primeira base de dados da máquina automática. Com isso, a base de dados apresenta 17 observações com as variáveis de constante dielétrica relativa da amostra, condutividade elétrica, altura e densidade aparente triplicadas, uma para cada valor de torque. Com isso, a base de dados também apresenta doze variáveis de entrada e uma de saída, a umi-

dade.

Análise da Primeira Base de Dados com Regressão Linear Múltipla

A mesma metodologia para a construção do modelo com regressão linear múltipla para a primeira base de dados da máquina manual foi utilizada para a máquina automática. Essa regressão obteve os coeficientes de acordo com a Tabela 3.4.

Tabela 3.4: Tabela de Coeficientes da Regressão Linear Múltipla da primeira base de dados da máquina automática.

Fonte: O Autor

	Coef. Estimados	SE	tStat	pValue
(Interseção)	$-7,3409 \times 10^{-16}$	0,029268	$-2,5082 \times 10^{-14}$	1
Torque	-0,041643	0,043297	-0,96179	0,34129
Altura	-0,083906	0,037403	-2,2433	0,029844
Densidade	-0,32454	0,045316	-7,1617	$5,8692 \times 10^{-9}$
Condutividade	-0,072868	0,035545	-2,05	0,046219
Const. Dielétrica	1,0848	0,04324	25,088	$4,3048 \times 10^{-28}$

Como também pode ser visto na Tabela 3.4, a única variável que não se mostrou correlacionada com a saída de acordo com o teste estatístico t foi o torque, com um p-value de 0,34129. Além disso, o RMSE ficou em 0,209, MAE em 0,7958% de umidade e \bar{R}^2 em 0,956. Esse modelo obteve uma incerteza de 1,9621% de umidade. Na Figura 3.23 é demonstrado o gráfico de alavancagem dessa regressão, no qual é possível visualizar que o modelo ficou mais centrado nos dados, o que se refletiu em um alto coeficiente de determinação.

Eliminando o torque do modelo, obtém-se os coeficientes de acordo com a Tabela 3.5.

Tabela 3.5: Tabela de Coeficientes da Regressão Linear Múltipla da primeira base de dados da máquina automática, removido o torque.

Fonte: O Autor

	Coef, Estimados	SE	tStat	pValue
(Interseção)	$-7,3461 \times 10^{-16}$	0,029244	$-2,512 \times 10^{-14}$	1
Altura	-0,062003	0,029646	-2,0914	0,042039
Densidade	-0,35017	0,036624	-9,5613	$1,6623 \times 10^{-12}$
Condutividade	-0,072141	0,035508	-2,0317	0,047989
Const. Dielétrica	1,0965	0,041467	26,442	$1,8319 \times 10^{-29}$

Esses coeficientes apresentam um RMSE em 0,209, MAE em 0,7980% umidade e um \bar{R}^2 de 0,956, os mesmos obtidos utilizando o torque. Além disso, esse modelo obteve uma incerteza de 1,9822% de umidade. Na Figura 3.24 é possível verificar que essa piora no valor de MAE não foi significativa.

Considerando que a faixa de interesse se situa acima de 7% de umidade em base úmida, a análise foi refeita excluindo as amostras menores que este patamar. Essa nova análise obteve os coeficientes de acordo com a Tabela 3.6.




Figura 3.23: Gráfico de alavancagem da regressão múltipla da primeira base de dados da máquina automática.

Fonte: O Autor

Tabela 3.6: Tabela de Coeficientes da Regressão Linear Múltipla da primeira base de dados da máquina automática, excluindo os dados com umidade abaixo de 7%.

Fonte: O Autor

	Coef. Estimados	SE	tStat	pValue
(Interseção)	0.50055	0.063418	7.8928	$4,0035 \times 10^{-8}$
Torque	-0.186	0.061467	-3.026	0.0058334
Altura	0.10016	0.046627	2.1481	0.042009
Densidade	0.3265	0.12537	2.6043	0.015553
Condutividade	-0.016774	0.028062	-0.59777	0.55559
Const. Dielétrica	0.28751	0.11998	2.3963	0.024709

Esses coeficientes apresentam um RMSE em 0,183, MAE de 0,3793% umidade e um \bar{R}^2 de 0,966, uma melhora significativa em relação ao uso de toda a base de dados, visto que o MAE reduziu mais de 0,4% de umidade. Além disso, esse modelo obteve uma incerteza de 0,9732% de umidade, mais de 1% em relação à toda base de dados. Na Figura 3.25 é possível verificar o gráfico com os dados ajustados, com a regressão. Como também pode ser visto na Tabela 3.6, a única variável que não se mostrou correlacionada com a saída de acordo com o teste estatístico t foi a condutividade, com um p-value de 0,55559.




Figura 3.24: Gráfico de alavancagem da regressão múltipla da primeira base de dados da máquina automática removendo o torque.

Fonte: O Autor

Análise da Segunda Base de Dados com Regressão Linear Múltipla

Na regressão linear múltipla desenvolvida em cima da segunda base de dados, também foi utilizada a mesma metodologia da segunda base de dados da máquina manual. Isso foi feito pelo mesmo motivo de melhor padronizar os dados e melhorar a efetividade da comparação. Essa regressão obteve os coeficientes de acordo com a Tabela 3.7

Como também pode ser visto na Tabela 3.7, todas as variáveis se mostraram não correlacionadas com a saída, de acordo com o teste estatístico t, visto que apresentaram um p-value acima de 0,05. Mas mesmo assim, o RMSE ficou em 0,141, MAE em 0,2663% de umidade e \bar{R}^2 em 0,98. Além disso, esse modelo obteve uma incerteza de 0,71% de umidade. Na Figura 3.26 é demonstrado o gráfico de alavancagem dessa regressão.

Não foi possível realizar uma análise realizando a eliminação dos dados menores que 7% para essa base de dados, devido a restarem 10 observações para 12 variáveis, o que causaria um *overfitting* nos dados.

Diferentemente do equipamento manual, os modelos identificados com regressão linear múltipla a partir das bases de dados construídas com o equipamento automático, obtiveram alto desempenho, apresentando um \bar{R}^2 acima de 95%, além de apresentarem excelentes índices de MAE. Isso se deve a eliminação dos erros de operação e a maior padronização do material utilizado para a preparação das amostras. A maior homogeneidade química e física, além da




Figura 3.25: Gráfico de alavancagem da regressão múltipla da primeira base de dados da máquina automática, excluindo os dados com umidade abaixo de 7%.

Fonte: O Autor

Tabela 3.7: Tabela de Coeficientes da Regressão Linear Múltipla da segunda base de dados da máquina automática.

Fonte: O Autor

	Coef. Estimados	SE	tStat	pValue
(Interseção)	$-1,3666 \times 10^{-13}$	0,034099	$-4,0078 \times 10^{-12}$	1
Const. Dielétrica 1	-0,37058	1,5267	-0,24274	0,82015
Const. Dielétrica 2	9,7728	5,5509	1,7606	0,15311
Const. Dielétrica 3	-8,9231	5,3137	-1,6792	0,1684
Condutividade 1	1,1334	0,96675	1,1723	0,30612
Condutividade 2	-1,4471	0,92219	-1,5692	0,19168
Condutividade 3	0,14548	0,67189	0,21652	0,83918
Altura 1	4,2562	4,1451	1,0268	0,36255
Altura 2	31,015	15,514	1,9992	0,11622
Altura 3	-30,779	15,268	-2,0159	0,11402
Densidade 1	3,5707	3,9598	0,90173	0,41819
Densidade 2	27,765	14,37	1,9321	0,12551
Densidade 3	-26,608	13,801	-1,9279	0,12612

padronização no processo de medição pelo equipamento automático proporcionaram uma maior estabilidade nos dados e reduziram a influência dos erros sobre o comportamento linear da umidade em relação aos parâmetros elétricos do modelo. Outro ponto de melhoria do equipamento automático em relação ao manual é a redução do tempo de resposta. Enquanto no equipamento




Figura 3.26: Gráfico de alavancagem da regressão múltipla da segunda base de dados da máquina automática.

Fonte: O Autor

manual o tempo de resposta ficou em 15 minutos, o equipamento automático apresentou um tempo de 1,5 minuto, com margem ainda para redução.

Devida a baixa quantidade de dados, não realizou-se análises utilizando RNA, mas recomenda-se, para trabalhos futuros, a avaliação do desempenho do equipamento automático nas mesmas condições avaliadas com o equipamento manual, visto que esse apresentou excelentes resultados com essa metodologia.

4 Conclusão

Neste trabalho foi desenvolvido um dispositivo para a medição de umidade de forma automatizada, para a redução do tempo de medição de umidade de minério de ferro em laboratório, visto que o método de medição gravimétrico, padrão no setor mineral, é uma técnica muito trabalhosa e com tempo de resposta muito elevado. Existem outras abordagens para entregar uma medição de umidade em tempo real no mercado, mas estas necessitam de investimento elevado, devido ao alto custo dos equipamentos e à nacionalização das tecnologias.

Foi projetada e construída a estrutura mecânica do equipamento, desenvolvida em sua maior parte em alumínio estrutural, sendo utilizados perfis estruturais e chapas de alumínio 6082-T6 com 15 mm de espessura, a fim de se obter uma estrutura leve e resistente. Essa estrutura foi simulada para validar o dimensionamento dos componentes e método construtivo, apresentando uma resistência com um fator de segurança 2 para uma força de 8 kN. As peças auxiliares, como o suporte da câmara de medição, suporte da célula de carga e outras foram construídas em aço ABNT 8640, temperadas em uma dureza de 48-52 HRC para que apresentem resistências mecânica e química elevadas.

Foi dimensionado um conjunto mecatrônico para a compactação da amostra, utilizando um servo motor Delta modelo ECMA-C20604, acoplado a um redutor planetário WPF60, com redução 12:1; fuso de esferas laminado com 20 mm de diâmetro e 5 mm de passo, além de ter sido desenvolvido um punção com sistema anti-giro. Esse sistema foi desenvolvido com o diferencial da movimentação ser feita pela castanha, possibilitando a fixação simples do motor na estrutura da prensa.

Foram aperfeiçoados os circuitos eletrônicos desenvolvidos em trabalhos anteriores, integrando em um Arduino Mega o controle geral do equipamento, proporcionando uma operação e coleta de dados automática. Também, utilizando análises feitas no circuito, foi proposto um novo método de calibração para o circuito de medição, eliminando a necessidade de se utilizar substâncias padrão como referência de condutividade e constante dielétrica. O novo método utiliza resistores e capacitores conhecidos como referência, aumentando a escalabilidade do dispositivo. O procedimento resultou em modelos de correção com R^2 superiores a 99,9%, com polinômios de primeira ordem.

Também foram avaliadas técnicas de regressão para a obtenção de modelos de umidade de minérios de ferro e comparar os equipamentos manual e automático. Foi utilizada a técnica de regressão linear múltipla para as bases de dados dos dois equipamentos e a rede neural artificial do tipo MLP para as bases de dados do equipamento manual. Enquanto os modelos obtidos para a máquina manual apresentaram R^2 de 51,4 e 52,6%, utilizando regressão múltipla, os modelos para a máquina automática apresentaram R^2 de 95,6 e 98%. Isso pode estar relacionado tanto a melhor padronização do processo de medição, quanto a maior padronização das amostras utilizadas na máquina automática, que teve parâmetros físicos e químicos bem definidos. Diferentemente dos modelos em regressão múltipla, os construídos com RNA obtiveram R^2 de

98,02 e 98,41%, desempenho superior. Isso se deve a capacidade de generalização e características não-lineares da RNA, que possibilita a abstração dos erros durante o treinamento e melhor extração das características relevantes para a regressão.

5 Trabalhos Futuros

Indica-se que o equipamento automático desenvolvido neste trabalho seja submetido a uma campanha de obtenção de uma base de dados similar à obtida com o equipamento manual, no Porto da Madeira, em São Luís-MA. Isso se faz necessário para que seja possível obter uma melhor comparação entre os equipamentos, a fim de constatar os resultados das melhorias efetuadas. Além disso, recomenda-se ampliar a quantidade de compressões e a faixa de compressão da amostra, para avaliar a influência e definir os limites da faixa e de quantidade de variáveis. Sugere-se também a avaliação da influência da composição mineral na medição, utilizando técnicas padrão, como os analisadores por fluorescência de raios-x utilizados no meio mineral e, posteriormente, pela incorporação de analisadores no equipamento. Após as melhorias, indica-se a avaliação de outras técnicas de inteligência artificial, a fim de escolher a que melhor se comporta para a base de dados que será construída.

Referências Bibliográficas

- ÁVILA, H. A. M. *Analizador De Umidade Por Microondas, Modelo Pmd 2450 Indutech*. Relatório técnico, Vale SA, Vitória, ES, 2010.
- BOYLESTAD, R. L. *Introdução à Análise de Circuitos*. N. 12. São Paulo, Brasil, Pearson, 2012. ISBN: 8587918184. Disponível em: <<http://books.google.com/books?id=Jmh4AAAACAAJ&pgis=1>>.
- BRAGA, A. P., CARVALHO, A. P. L. F., LUDEMIR, T. B. *Redes Neurais Artificiais, Teoria e Aplicações. Livros Técnicos e Científicos*. N. 2 Edição. Rio de Janeiro, Brasil, 2007.
- BRASIL. “Lei No 9.605 de 12 de fevereiro de 1998. Dispõe sobre as sanções penais e administrativas derivadas de condutas e atividades lesivas ao meio ambiente, e dá outras providências.” 1998.
- CUNHA, G. R., BERGAMASCHI, H., CT, B., et al.. *Agrometeorologia aplicada à irrigação*. Porto Alegre, RS, UFRGS, 1992. ISBN: 85-7025-221-8.
- ENGELBRECHT, A. P. *Computational Intelligence*. Chichester, UK, John Wiley & Sons, Ltd, oct 2007. ISBN: 9780470512517. doi: 10.1002/9780470512517. Disponível em: <<http://doi.wiley.com/10.1002/9780470512517>>.
- FERREIRA, R. F., POLICARPO, D. L. V., PADULA, V. P., et al.. “Limite De Umidade Transportável De Minérios De Ferro: Aspectos Regulatórios E Técnicos”, *Tecnologia em Metalurgia Materiais e Mineração*, v. 14, n. 1, pp. 16, 2017. ISSN: 2176-1515. doi: 10.4322/2176-1523.1149. Disponível em: <<http://tecnologiामmm.com.br/doi/10.4322/2176-1523.1149>>.
- ISO 3087:2020. “Iron ores — Determination of the moisture content of a lot”. 2020.
- KEYSIGHT TECHNOLOGIES. “Basics of Measuring the Dielectric Properties of Materials Appl. Note 5989-2589EN.” p. 34, 2017.
- LAGE, V. N. *Desenvolvimento de sistema de bancada para medição de umidade de minérios*. Tese de Mestrado, Universidade Federal de Ouro Preto (UFOP) e Instituto Tecnológico Vale (ITV-MI), Ouro Preto, Minas Gerais., 2018.

- OF ILLINOIS AT URBANA-CHAMPAIGN. CENTER FOR SUPERCOMPUTING RESEARCH, U., DEVELOPMENT, CYBENKO, G. *Continuous valued neural networks with two hidden layers are sufficient*. Chicago, Illinois., 1988.
- PINTO, E. S., SANTOS, G. A., MAGALHAES, P. H. V., et al.. “A novel two degrees of freedom system for measuring iron ore water content on a conveyor belt”, *IEEE Sensors Journal*, pp. 1–1, 2021. ISSN: 1530-437X. doi: 10.1109/JSEN.2021.3076428. Disponível em: <<https://ieeexplore.ieee.org/document/9419052/>>.
- PINTO, É. S. *Desenvolvimento de um Sistema de Medição de Umidade de Minério de Ferro em Correia Transportadora*. Tese de Mestrado, Universidade Federal de Ouro Preto (UFOP) e Instituto Tecnológico Vale (ITV-MI), Ouro Preto, Minas Gerais., 2019.
- PINTO, T. C. D. S., DE MORAES JUNIOR, D., LIA, L. R. B., et al.. “Mecanismos De Secagem Visando a Redução De Umidade Em Sinter Feed De Minério De Ferro”. v. 45, pp. 1016–1024, São Paulo, 2017. Editora Blucher. doi: 10.5151/2594-357x-27360.
- RÊGO SEGUNDO, A. K. *Desenvolvimento De Um Sistema De Controle Automático Para Processo De Irrigação E Fertilização*. Tese de Doutorado, Tese (Doutorado em Engenharia Agrícola), Departamento de Engenharia Agrícola, Universidade Federal de Viçosa, Viçosa, 2014.
- RÊGO SEGUNDO, A. K., SILVA, C. C. A. F. D., PINTO, É. S., et al.. “**Sistema e método para medição de umidade de uma amostra de solo ou minério. - BR10201901671**”. 2019.
- RESNICK, R., HALLIDAY, D. *Fundamentos de Física*, v. 3. Rio De Janeiro, Brasil, 2009.
- SANTOS, G. A. *Desenvolvimento de um Sensor Capacitivo para Monitoramento da Umidade do Minério de Ferro em Protótipo de Vagão de Trem*. Tese de Mestrado, Universidade Federal de Ouro Preto (UFOP) e Instituto Tecnológico Vale (ITV-MI), Ouro Preto, Minas Gerais., 2020.
- SEGUNDO, A. K. R., MARTINS, J. H., MONTEIRO, P. M. D. B., et al.. “A novel low-cost instrumentation system for measuring the water content and apparent electrical conductivity of soils”, *Sensors (Switzerland)*, v. 15, n. 10, pp. 25546–25563, oct 2015. ISSN: 14248220. doi: 10.3390/s151025546. Disponível em: <<http://www.mdpi.com/1424-8220/15/10/25546>>.
- SEGUNDO, A. K. R., PINTO, E. S., DE BARROS MONTEIRO, P. M., et al.. “Sensor for measuring electrical parameters of soil based on auto-balancing bridge circuit”. In: *Proceedings of IEEE Sensors*, v. 2017-Decem, pp. 1–3, Glasgow, Scotland, oct 2017. IEEE. ISBN: 9781509010127. doi: 10.1109/ICSENS.2017.8234001.

Disponível em: <<http://ieeexplore.ieee.org/document/8234001/https://ieeexplore.ieee.org/document/8234001/>>.

SEGUNDO, A. K. R., DA SILVA, M. J., FREITAS, G. M., et al.. “Reply to comments: A novel low-cost instrumentation system for measuring the water content and apparent electrical conductivity of soils, sensors, 15, 25546–25563”, *Sensors (Switzerland)*, v. 18, n. 6, pp. 1742, may 2018. ISSN: 14248220. doi: 10.3390/s18061742. Disponível em: <<https://www.mdpi.com/1424-8220/18/6/1742http://www.mdpi.com/1424-8220/18/6/1742>>.

SEGUNDO, A. K. R., PINTO, É. S., SANTOS, G. A., et al.. “Capacitive impedance measurement: Dual-frequency approach”, *Sensors (Switzerland)*, v. 19, n. 11, pp. 2539, jun 2019. ISSN: 14248220. doi: 10.3390/s19112539. Disponível em: <<https://www.mdpi.com/1424-8220/19/11/2539>>.

SILVA, M. E. H. *Desenvolvimento de um transdutor capacitivo, coplanar e não-invasivo para medição on-line de umidade do minério de ferro em silos*. Tese de Mestrado, Universidade Federal de Ouro Preto (UFOP) e Instituto Tecnológico Vale (ITV-MI), Ouro Preto, Minas Gerais., 2019.


SILVA, M. *Impedance Sensors for Fast Multiphase Flow Measurement and Imaging*. *Doctoral Thesis*. Tese de Doutorado, 2008.

VALE, I. T. “**Redução da Umidade do Minério**”. 2020. Disponível em: <<http://www.itv.org/inovacao/reducao-da-umidade-do-minerio/>>.

YU, H., WILAMOWSKI, B. M. *Intelligent Systems*. Boca Raton, Flórida, EUA, CRC Press, oct 2018. ISBN: 9781315218427. doi: 10.1201/9781315218427. Disponível em: <<https://www.taylorfrancis.com/books/9781439802847>>.


APÊNDICE

APÊNDICE A: Desenhos Conjunto




ITEM NO.	PART NUMBER	DESCRIÇÃO	QTY.
1	EP-0001-002-01	Caixa	1
2	EP-0001-002-02	Placa Sensor	2

CASO NÃO ESPECIFICADO: DIMENSÕES ESTÃO EM MILÍMETROS ACABAMENTO SUPERFICIAL: TOLERÂNCIAS: NBR ISO 2768-2				ACABAMENTO:		REMOVER REBRBAS E QUEBRAR CANTOS VIVOS		NÃO DIMENSIONE O DESENHO		REVISÃO 001	
DESENH		NOME M. NEIVA		ASSINATURA		DATA 11/09/21		TÍTULO: Conjunto Caixa		NO.	
CONF.								EP-0001-002-00		A3	
APROV.								MATERIAL:		PÁGINA 1 DE 1	
								MASSA:		ESCALA:1:2	




ITEM NO.	PART NUMBER	DESCRIÇÃO	SUPPLIER	QTY.
1	PWZL-4F	Célula de Carga 20kgf	MK CONTROLE E INSTRUMENTAÇÃO	1
2	EP-0001-001-01	Suporte da Caixa		1

CASO NÃO ESPECIFICADO: DIMENSÕES ESTÃO EM MILÍMETROS ACABAMENTO SUPERFICIAL: TOLERÂNCIAS: NBR ISO 2768-2				ACABAMENTO:		REMOVER REBRBAS E QUEBRAR CANTOS VIVOS		NÃO DIMENSIONE O DESENHO		REVISÃO 001	
DESENH		NOME M. NEIVA		ASSINATURA		DATA 11/09/21		TÍTULO: CONJUNTO CÉLULA DE CARGA			
CONF.								NO. EP-0001-001-00			
APROV.								A3			
								ESCALA:1:2			
								PÁGINA 1 DE 1			




ITEM NO.	PART NUMBER	DESCRIÇÃO	SUPPLIER	QTY.
1	KMNR7	Mini Guia Linear	Kalatec Automação	1
2	KMNS7C	Patim Mini Guia Linear 7mm	Kalatec Automação	1
3	KTC42HS48-1004AL	Motor de Passo Com Fuso	Kalatec Automação	1
4	Castanha	Castanha para Fuso Motor de Passo KTC42HS48-1004AL	Kalatec Automação	1
5	EP-0001-005-01	Calço		1

CASO NÃO ESPECIFICADO: DIMENSÕES ESTÃO EM MILÍMETROS ACABAMENTO SUPERFICIAL: TOLERÂNCIAS: NBR ISO 2768-2				ACABAMENTO:		REMOVER REBRBAS E QUEBRAR CANTOS VIVOS		NÃO DIMENSIONE O DESENHO		REVISÃO 001	
DESENH CONF. APROV.				NOME M. NEIVA		ASSINATURA		DATA 11/09/21		TÍTULO: Conjunto Calço	
								NO.		EP-0001-005-00	
								MATERIAL:		A3	
								MASSA:		PÁGINA 1 DE 1	
								ESCALA:1:1			




ITEM NO.	PART NUMBER	DESCRIÇÃO	SUPPLIER	QTY.
1	EP-0001-001-00	Conjunto Célula de Carga		1
2	EP-0001-002-00	Conjunto Caixa		1
3	EP-0001-003-00	Conjunto Compressão		1
4	EP-0001-004-00	Proteção/Estrutura		1
5	EP-0001-005-00	Conjunto Calço		1
6	AZM300B_I2_ST_1P2P_	Trava Nível 4	SCHMERSAL	1
7	AZ_AZM300_B1	Trava Nível 4	SCHMERSAL	1
8	PAINEL ELÉTRICO	Painel Elétrico CEMAR Legrand 400X300x200mm		1

CASO NÃO ESPECIFICADO: DIMENSÕES ESTÃO EM MILÍMETROS ACABAMENTO SUPERFICIAL: TOLERÂNCIAS: NBR ISO 2768-2		ACABAMENTO:		REMOVER REBRBAS E QUEBRAR CANTOS VIVOS		NÃO DIMENSIONE O DESENHO		REVISÃO 001	
DESENH CONF. APROV.		NOME M. NEIVA		ASSINATURA		DATA 11/09/21		TÍTULO: Conjunto Geral	
								NO. EP-0001-000-00	
								A3	
								PÁGINA 1 DE 1	



ITEM NO.	PART NUMBER	DESCRIÇÃO	SUPPLIER	QTY.
1	3842557216-420mm	Perfil estrutural 30X30X420mm	BOSCH REXROTH	4
2	3842557216-210mm	Perfil estrutural 30X30X210mm	BOSCH REXROTH	4
3	3842557216-240mm	Perfil estrutural 30X30X240mm	BOSCH REXROTH	4
4	3842523528	Bracket 30x30 set (standard) N8/8	Bosch Rexroth	12
5	3842535578	Inner bracket, N8/8	Bosch Rexroth	4
6	3842544526	Hinge, aluminum P1=20 P2=30	Bosch Rexroth	2
7	EP-0001-004-06	Porta		1
8	EP-0001-004-01	Base Geral		1
9	EP-0001-004-02	Topo		1
10	EP-0001-004-03	Base Sensor		1
11	EP-0001-004-04	Gaveta		1
12	EP-0001-004-05	Apoio Guia		1

CASO NÃO ESPECIFICADO: DIMENSÕES ESTÃO EM MILÍMETROS ACABAMENTO SUPERFICIAL: TOLERÂNCIAS: NBR ISO 2768-2				ACABAMENTO:		REMOVER REBRBAS E QUEBRAR CANTOS VIVOS		NÃO DIMENSIONE O DESENHO		REVISÃO 001	
DESENH CONF. APROV.				NOME M. NEIVA		ASSINATURA		DATA 11/09/21		TÍTULO: Proteção/Estrutura	
								NO.		EP-0001-004-00	
						MATERIAL:		ESCALA:1:5		PÁGINA 1 DE 1	
						MASSA:				A3	



ITEM NO.	PART NUMBER	DESCRIÇÃO	SUPPLIER	QTY.
1	EP-0001-003-01	Punção		1
2	SFUR2005	Castanha para Fuso SFUR2005	Kalatec Automação	1
3	SFU2005	Fuso de Esferas SFUR2005	Kalatec Automação	1
4	SCL2-25	Acoplamento de Discos 25Nm	R+W Couplings	1
5	WPF060-L1-10-C20604	Redutor Planetário	Kalatec Automação	1
6	ECMA-C20604	Servo Motor Delta 400W com ServoDrive ASD-A2-0421-M	Delta Electronics	1
7	LM10UU	Rolamento Linear	Kalatec Automação	1

CASO NÃO ESPECIFICADO: DIMENSÕES ESTÃO EM MILÍMETROS ACABAMENTO SUPERFICIAL: TOLERÂNCIAS: NBR ISO 2768-2		ACABAMENTO:		REMOVER REBRBAS E QUEBRAR CANTOS VIVOS		NÃO DIMENSIONE O DESENHO		REVISÃO 001	
DESENH		NOME		ASSINATURA		DATA		TÍTULO:	
CONF.		M. NEIVA				11/09/21		Conjunto de Compressão	
APROV.								NO.	
								EP-0001-003-00	
								A3	
								ESCALA:1:5	
								PÁGINA 1 DE 1	

APÊNDICE B: Bases de Dados

Primeira base de dados do Equipamento Manual

Torque (N/m)	Altura (mm)	Densidade1(kg/m³)	CondCorr1(uS/m)	DielCorr1	Umidade (%)
2,05	63,7	2744,51367	58,4501353	69,2166337	8,37
5,19	59,4	2943,19059	73,7532048	83,6900171	8,37
10,12	57,4	3045,74078	81,0683031	89,8058987	8,37
2,15	60,7	2783,9271	68,7076865	68,206961	8,67
5,2	57,5	2938,8587	79,26875	77,3742375	8,67
10,05	55,4	3050,25948	87,8580485	84,2108027	8,67
2,02	62,2	2775,57275	55,9782629	68,6231015	8,43
5,24	59,6	2896,65478	64,2000999	76,7041231	8,43
10,26	56,1	3077,37299	75,9684685	87,2304512	8,43
2,11	61,3	2783,05975	63,741552	62,6167014	8,89
5,08	59,4	2872,08018	70,2635798	68,2360976	8,89
10,09	57,1	2987,76817	77,9398804	74,962124	8,89
2,06	64,1	2757,28842	62,5070131	66,1306439	8,43
5,19	60,7	2911,73291	72,5958161	75,460751	8,43
10,55	58,1	3042,03421	82,3904974	83,9484728	8,43
2,19	65,2	2794,48652	72,1961448	64,2446971	8,84
5,19	63,6	2864,78806	78,858197	69,5866812	8,84
10,07	61	2986,89378	89,4748177	78,1156913	8,84
2,15	61,1	2707,8645	54,1219759	45,0902289	8,4
5,1	59,1	2799,5012	60,0036357	50,5715316	8,4
10,17	57,2	2892,49162	65,5809388	55,4725057	8,4
2,16	63,1	2673,2947	49,874206	36,6392906	8,69
5,18	58,7	2797,42779	57,2297539	43,3921227	8,69
10,13	58,7	2873,67795	62,1555098	47,7151935	8,69
2,33	64,8	2651,18634	53,8282377	38,2686112	8,31
5,17	62,4	2753,15505	61,7678495	44,9868392	8,31
10,29	60,8	2825,6065	66,071569	48,6605098	8,31
2,07	67,1	2674,8401	46,8249703	45,9555307	8,32
5,07	63,5	2826,48458	56,3064672	55,515863	8,32
10,04	61,1	2937,50852	63,2037607	62,0622982	8,32
2,67	64,3	2724,65494	52,9421312	61,4199382	8,29
5,25	62	2825,73085	59,7687389	68,3441105	8,29
10,06	59	2969,41208	69,329944	77,3320707	8,29
2,33	64,2	2529,28673	43,8633565	24,8448171	8,61
5,09	60,5	2683,97039	52,8466948	32,4449904	8,61
10,04	58,5	2775,73006	57,8662635	36,513185	8,61
2,11	65,9	2603,17874	49,2850682	28,2099717	8,55
5,24	64,2	2672,11027	53,8574883	32,1904343	8,55
10,16	61,7	2780,38054	60,4322883	37,7258572	8,55
2,48	69,5	2495,01649	45,6070631	33,5576389	8,39
5,14	64,7	2680,11817	57,7383642	45,2712314	8,39

10	62,6	2770,02629	63,200495	50,5903939	8,39
2,22	66,8	2649,23278	65,7381378	54,6392772	8,87
5,11	62,1	2849,73833	81,9794802	68,7773734	8,87
10,33	60,4	2929,94619	89,2438974	74,6000575	8,87
2,15	64,3	2700,63828	82,5016123	72,9972543	8,87
5,07	59,9	2899,01572	100,746491	86,5197191	8,87
10,11	57,5	3020,01812	109,668114	93,5714211	8,87
2,07	62,2	2677,8537	78,1146419	72,5673319	8,69
5,09	59,1	2818,31641	90,2113433	82,4689933	8,69
10,19	56,8	2932,43838	99,904337	89,8755329	8,69
2,14	68,7	2603,82551	67,8808996	63,7230868	8,65
5,11	64,4	2777,68342	84,260999	77,5597948	8,65
10,15	59,8	2991,35138	103,410025	91,6904708	8,65
2,07	65,4	2741,58225	66,8939386	72,1194258	8,24
5,09	62,4	2873,38909	77,8940481	81,9306689	8,24
10,07	61,6	2910,70583	84,9365535	87,9429133	8,24
2,1	63	2673,9418	31,5836608	48,2832992	7,78
5,21	60,3	2793,67054	37,157799	55,629111	7,78
10,13	57,6	2924,62384	42,6544496	62,7067562	7,78
2,03	65	2609,53526	60,1602296	29,3855512	9,22
5,02	62,2	2727,0063	67,7794595	35,1580349	9,22
10,03	59,9	2831,71605	74,745998	40,2452927	9,22
2,1	66,2	2582,1768	48,4770855	26,7135984	8,79
5,03	63,4	2696,21615	53,4829432	31,7787103	8,79
10,32	61,2	2793,13896	59,2202951	36,4988501	8,79
2,07	62,5	2709,83333	47,7047176	51,0599976	8,57
5,19	58,8	2880,35006	57,850532	61,6469657	8,57
10,3	56,9	2976,53046	63,1359612	66,7576683	8,57
2,21	62,3	2762,71569	50,0250232	57,2756057	8,16
5,09	60,4	2849,62231	54,946125	62,3852923	8,16
10,03	58,6	2937,15337	59,9747049	67,4891238	8,16
2,18	63,7	2731,18622	46,3782433	44,3219721	7,98
5,16	61,9	2810,60683	50,7350634	49,1704173	7,98
10,15	59,7	2914,18028	56,7605857	55,3198804	7,98
2,14	66,7	2547,63243	38,6821811	22,115579	8,13
5,11	63,6	2671,80949	45,8691063	28,4536591	8,13
10,1	61,7	2754,08563	51,0669608	32,8627473	8,13
2,24	64,5	2680,43443	26,5025821	46,9505541	7,24
5,03	61,3	2820,35923	32,7443059	56,0947675	7,24
10	58,7	2945,28145	38,7339767	64,3351425	7,24
2,07	62,4	2692,22423	29,7974608	47,9862872	7,26
5,05	59	2847,36935	36,5189773	57,0951187	7,26
10,19	57	2947,27705	40,8378952	62,7428306	7,26
2,16	62,9	2703,77915	27,5031942	45,8751168	7,37
5,38	59,7	2848,70533	33,4614007	54,695419	7,37

10,14	57,7	2947,44728	37,5798677	60,4129176	7,37
2,21	67,2	2531,9708	38,3435693	28,0335555	7,81
5,26	63,5	2679,50295	46,6814131	36,215213	7,81
10,37	61,4	2771,14719	52,142791	41,7887953	7,81
2,16	63,8	2688,53677	59,0389932	69,7740277	8,55
5,23	59,4	2887,68764	74,9629432	84,4937292	8,55
10,26	56,8	3019,87053	86,6903451	93,975599	8,55
2,17	62,9	2758,42939	62,534121	73,2273702	8,55
5,14	60	2891,75347	72,9303575	82,8262269	8,55
10,32	57,2	3033,30784	81,8714221	90,1976654	8,55
2,05	64,8	2713,47737	57,4922837	67,7493059	8,55
5,32	60,9	2887,24685	70,3003008	79,9913656	8,55
10,49	58,8	2990,36281	77,8062512	86,7520788	8,55
2,02	66,7	2593,85932	36,9972326	45,8931051	8
5,43	62	2790,49059	46,9533254	59,119879	8
10,65	58,9	2937,35852	55,7122897	69,0802718	8
2,04	66,5	2611,92043	39,020585	50,4314025	8
5,14	62,7	2770,21863	51,1702502	64,3505481	8
10,57	59,7	2909,4256	56,8248102	70,3905303	8
2,04	63,6	2694,00223	41,2540676	54,2916519	8
5,71	59,9	2860,40971	50,4548829	64,6718705	8
10,15	58,5	2928,86396	53,9797082	68,6792336	8
2,09	66,8	2641,20197	54,6568112	42,2212541	8,51
5,24	63	2800,51257	64,445125	51,5154847	8,51
10,09	61,4	2873,49009	69,3822569	55,9872875	8,51
2,12	64,4	2611,00058	49,5916508	38,1248824	8,51
5,1	60,9	2761,05809	58,4815253	46,2820765	8,51
10,3	59	2849,97352	64,1138424	51,5602614	8,51
2,21	68,9	2487,41382	44,2933908	33,0195994	8,51
5,11	62,4	2746,51943	59,5833527	47,2448373	8,51
10,04	59,5	2880,3834	67,7988863	54,4785005	8,51
2,3	66,2	2648,34309	60,3496633	45,7122915	8,76
5,09	63,7	2752,2812	68,0187936	52,4800412	8,76
10,2	61,4	2855,37968	75,0851465	58,5740107	8,76
2,66	64,3	2598,09163	52,133773	39,3824777	8,76
5,05	61	2738,64413	61,1285319	47,5137906	8,76
10,8	58,8	2841,1104	68,1457954	53,6927895	8,76
2,46	72	2510,52517	46,4949485	33,9422886	8,76
5,08	67	2697,8778	60,0954733	46,5203816	8,76
10,09	64,5	2802,44671	67,5542576	52,9939425	8,76
2,11	69,6	2544,41301	37,023495	40,9662315	8,33
5,04	67,1	2639,21231	42,7365946	47,3106932	8,33
10,07	59,3	2986,35996	65,5264466	69,9011429	8,33
2,24	72,6	2618,08425	55,3208916	42,4086281	8,5
5,31	67,8	2803,43535	69,0294509	54,5992027	8,5

10,29	65,6	2897,453	76,0375889	60,4179337	8,5
2,31	67,6	2640,10879	57,7561157	36,4400591	8,67
5,22	65,2	2737,29071	64,6973858	42,1647571	8,67
10,28	62,8	2841,90054	71,8674109	48,0435173	8,67
2,15	66,9	2580,26594	49,7759007	33,8837483	8,61
5,11	62,4	2766,34282	62,3782322	45,2213956	8,61
10,61	60,3	2862,68311	69,4864251	51,6223079	8,61
2,21	69,1	2661,52617	50,7199324	35,5859514	8,47
5,14	66,4	2769,75088	57,7351825	42,1018352	8,47
10,23	62,4	2947,29901	69,665047	52,6044607	8,47
2,13	69,3	2589,32329	44,5059413	42,3945991	8,14
5,22	65,7	2731,20402	57,4976972	52,872304	8,14
10,12	63,3	2834,75678	60,9569608	58,7398472	8,14
2,27	69,4	2587,95629	61,3418867	34,7483538	8,08
5,12	66,5	2700,81454	70,3666702	41,7778117	8,08
10,03	64,5	2784,56072	77,4084445	47,6236664	8,08
2,07	68	2699,71661	41,552459	55,5053904	8,02
5,19	64,1	2863,97393	52,3440655	67,5243815	8,02
10,16	61,3	2994,79167	60,9446687	76,4651613	8,02
2,18	69,9	2617,50417	32,8857531	48,347294	7,68
5,28	66,6	2747,20033	40,1617375	57,5333751	7,68
10,28	64,3	2845,46721	46,8343872	65,8029107	7,68
2,27	69,7	2707,81026	69,513795	67,3885916	8,93
5,13	65,5	2881,44084	83,9079067	79,431333	8,93
10,08	63,1	2991,03605	94,5961419	87,6396869	8,93
2,13	69,2	2666,59893	64,4993996	61,6807769	8,83
5,14	65,7	2808,65519	76,2194804	71,9366303	8,83
10,21	63,1	2924,38424	86,8551147	80,6880756	8,83
2,16	69,3	2554,22529	57,4003547	29,7133999	8,97
5,23	65	2723,19712	69,8179529	39,2884268	8,97
10,16	63,2	2800,75653	75,6551252	43,5665804	8,97
2,15	69,9	2679,72103	44,5503652	51,6199136	7,99
5,31	65,8	2846,69453	49,0366363	61,3430508	7,99
10,28	63,9	2931,33803	54,3042664	67,0469482	7,99
2,45	74,9	2523,36449	51,771303	50,9281733	8,1
5,15	71,9	2628,6509	55,2559734	57,3937695	8,1
10,06	67,8	2787,61062	66,8879261	68,7067522	8,1
2,11	72,3	2560,54778	70,1766669	40,6154399	7,89
5,35	67,9	2726,47429	84,757556	51,897386	7,89
10,13	65,8	2813,48943	92,1553324	57,1225097	7,89
2,11	70,1	2603,27508	73,9355118	42,6877072	7,98
5,31	66,8	2731,87999	87,015072	52,1651567	7,98
10,18	64,6	2824,91615	97,5330676	58,7386192	7,98
2,13	69,8	2604,42783	30,9237523	40,1981665	7,55
5,18	66,8	2721,39315	36,2175848	47,5048302	7,55

10,28	64,3	2827,20159	42,0178648	54,6877066	7,55
2,66	69,5	2577,11331	59,4747612	36,6501076	7,93
5,25	66,4	2697,43035	69,9658313	45,0543747	7,93
10,35	64,5	2776,88953	76,9579946	50,5941401	7,93
2	67,4	2746,15943	64,0030649	71,8361101	8,49
5,18	64,6	2865,18802	73,4385909	80,386817	8,49
10,24	62,1	2980,53375	82,6340462	88,0906969	8,49

Segunda Base de dados Equipamento Manual

Er	Er2	Er3	Sigma (uS/m)	Sigma2 (uS/m)	Sigma3 (uS/m)	Altura (mm)	Altura2 (mm)	Altura3 (mm)	DENSID. 1 (kg/m³)	DENSID. 2 (kg/m³)	DENSID. 3 (kg/m³)	Umidade (%)
69,21663	83,69002	89,8059	58,45014	73,7532	81,0683	63,7	59,4	57,4	2744,513671	2938,858696	3045,740781	8,37
68,20696	77,37424	84,2108	68,70769	79,26875	87,85805	60,7	57,5	55,4	2783,9271	2896,654782	3050,259477	8,67
68,6231	76,70412	87,23045	55,97826	64,2001	75,96847	62,2	59,6	56,1	2775,572749	2872,080177	3077,372995	8,43
62,6167	68,2361	74,96212	63,74155	70,26358	77,93988	61,3	59,4	57,1	2783,059747	2911,732908	2987,76817	8,89
66,13064	75,46075	83,94847	62,50701	72,59582	82,3905	64,1	60,7	58,1	2757,288417	2864,788063	3042,034208	8,43
64,2447	69,58668	78,11569	72,19614	78,8582	89,47482	65,2	63,6	61	2794,486516	2799,501199	2986,893784	8,84
45,09023	50,57153	55,47251	54,12198	60,00364	65,58094	61,1	59,1	57,2	2707,864498	2797,427792	2892,491623	8,4
36,63929	43,39212	47,71519	49,87421	57,22975	62,15551	63,1	58,7	58,7	2673,294704	2753,155048	2873,677953	8,69
38,26861	44,98684	48,66051	53,82824	61,76785	66,07157	64,8	62,4	60,8	2651,186343	2826,48458	2825,606497	8,31
45,95553	55,51586	62,0623	46,82497	56,30647	63,20376	67,1	63,5	61,1	2674,840102	2825,730847	2937,508524	8,32
61,41994	68,34411	77,33207	52,94213	59,76874	69,32994	64,3	62	59	2724,654938	2683,970386	2969,412076	8,29
24,84482	32,44499	36,51318	43,86336	52,84669	57,86626	64,2	60,5	58,5	2529,286734	2672,110267	2775,730057	8,61
28,20997	32,19043	37,72586	49,28507	53,85749	60,43229	65,9	64,2	61,7	2603,178743	2680,118174	2780,380538	8,55
33,55764	45,27123	50,59039	45,60706	57,73836	63,2005	69,5	64,7	62,6	2495,016487	2849,738325	2770,026291	8,39
54,63928	68,77737	74,60006	65,73814	81,97948	89,2439	66,8	62,1	60,4	2649,232784	2899,015721	2929,946192	8,87
72,99725	86,51972	93,57142	82,50161	100,7465	109,6681	64,3	59,9	57,5	2700,638284	2818,316413	3020,018116	8,87
72,56733	82,46899	89,87553	78,11464	90,21134	99,90434	62,2	59,1	56,8	2677,853698	2777,683424	2932,43838	8,69
63,72309	77,55979	91,69047	67,8809	84,261	103,41	68,7	64,4	59,8	2603,825509	2873,389089	2991,35138	8,65
72,11943	81,93067	87,94291	66,89394	77,89405	84,93655	65,4	62,4	61,6	2741,58225	2793,670536	2910,705831	8,24
48,2833	55,62911	62,70676	31,58366	37,1578	42,65445	63	60,3	57,6	2673,941799	2727,006297	2924,623843	7,78
29,38555	35,15803	40,24529	60,16023	67,77946	74,746	65	62,2	59,9	2609,535256	2696,216154	2831,716055	9,22
26,7136	31,77871	36,49885	48,47709	53,48294	59,2203	66,2	63,4	61,2	2582,1768	2880,350057	2793,138957	8,79
51,06	61,64697	66,75767	47,70472	57,85053	63,13596	62,5	58,8	56,9	2709,833333	2849,62231	2976,530463	8,57
57,27561	62,38529	67,48912	50,02502	54,94612	59,9747	62,3	60,4	58,6	2762,71569	2810,606826	2937,15337	8,16

44,32197	49,17042	55,31988	46,37824	50,73506	56,76059	63,7	61,9	59,7	2731,186224	2671,809486	2914,180276	7,98
22,11558	28,45366	32,86275	38,68218	45,86911	51,06696	66,7	63,6	61,7	2547,632434	2820,359231	2754,085629	8,13
46,95055	56,09477	64,33514	26,50258	32,74431	38,73398	64,5	61,3	58,7	2680,434432	2847,36935	2945,281445	7,24
47,98629	57,09512	62,74283	29,79746	36,51898	40,8379	62,4	59	57	2692,224225	2848,705332	2947,277047	7,26
45,87512	54,69542	60,41292	27,50319	33,4614	37,57987	62,9	59,7	57,7	2703,779147	2679,502953	2947,447285	7,37
28,03356	36,21521	41,7888	38,34357	46,68141	52,14279	67,2	63,5	61,4	2531,970796	2887,68764	2771,147191	7,81
69,77403	84,49373	93,9756	59,03899	74,96294	86,69035	63,8	59,4	56,8	2688,536769	2891,753472	3019,870525	8,55
73,22737	82,82623	90,19767	62,53412	72,93036	81,87142	62,9	60	57,2	2758,429385	2887,246853	3033,307838	8,55
67,74931	79,99137	86,75208	57,49228	70,3003	77,80625	64,8	60,9	58,8	2713,477366	2790,490591	2990,362812	8,55
45,89311	59,11988	69,08027	36,99723	46,95333	55,71229	66,7	62	58,9	2593,85932	2770,218634	2937,358517	8
50,4314	64,35055	70,39053	39,02058	51,17025	56,82481	66,5	62,7	59,7	2611,920426	2860,409711	2909,4256	8
54,29165	64,67187	68,67923	41,25407	50,45488	53,97971	63,6	59,9	58,5	2694,002227	2800,512566	2928,86396	8
42,22125	51,51548	55,98729	54,65681	64,44513	69,38226	66,8	63	61,4	2641,201971	2761,058087	2873,490092	8,51
38,12488	46,28208	51,56026	49,59165	58,48153	64,11384	64,4	60,9	59	2611,000582	2746,519431	2849,973517	8,51
33,0196	47,24484	54,4785	44,29339	59,58335	67,79889	68,9	62,4	59,5	2487,413824	2752,281201	2880,383403	8,51
45,71229	52,48004	58,57401	60,34966	68,01879	75,08515	66,2	63,7	61,4	2648,343089	2738,644126	2855,379682	8,76
39,38248	47,51379	53,69279	52,13377	61,12853	68,1458	64,3	61	58,8	2598,091628	2697,877799	2841,110402	8,76
33,94229	46,52038	52,99394	46,49495	60,09547	67,55426	72	67	64,5	2510,525174	2639,212308	2802,446705	8,76
40,96623	47,31069	69,90114	37,0235	42,73659	65,52645	69,6	67,1	59,3	2544,413015	2803,435349	2986,359963	8,33
42,40863	54,5992	60,41793	55,32089	69,02945	76,03759	72,6	67,8	65,6	2618,084252	2737,290708	2897,452998	8,5
36,44006	42,16476	48,04352	57,75612	64,69739	71,86741	67,6	65,2	62,8	2640,108789	2766,342815	2841,900544	8,67
33,88375	45,2214	51,62231	49,7759	62,37823	69,48643	66,9	62,4	60,3	2580,265944	2769,750879	2862,683112	8,61
35,58595	42,10184	52,60446	50,71993	57,73518	69,66505	69,1	66,4	62,4	2661,52617	2731,204021	2947,299012	8,47
42,3946	52,8723	58,73985	44,50594	57,4977	60,95696	69,3	65,7	63,3	2589,323292	2700,814536	2834,75678	8,14
34,74835	41,77781	47,62367	61,34189	70,36667	77,40844	69,4	66,5	64,5	2587,956292	2863,973934	2784,560724	8,08
55,50539	67,52438	76,46516	41,55246	52,34407	60,94467	68	64,1	61,3	2699,716605	2747,200325	2994,791667	8,02
48,34729	57,53338	65,80291	32,88575	40,16174	46,83439	69,9	66,6	64,3	2617,504173	2881,44084	2845,467211	7,68

67,38859	79,43133	87,63969	69,5138	83,90791	94,59614	69,7	65,5	63,1	2707,810258	2808,655188	2991,036054	8,93
61,68078	71,93663	80,68808	64,4994	76,21948	86,85511	69,2	65,7	63,1	2666,598928	2723,197115	2924,384245	8,83
29,7134	39,28843	43,56658	57,40035	69,81795	75,65513	69,3	65	63,2	2554,225289	2846,694529	2800,756527	8,97
51,61991	61,34305	67,04695	44,55037	49,03664	54,30427	69,9	65,8	63,9	2679,72103	2628,650904	2931,338028	7,99
50,92817	57,39377	68,70675	51,7713	55,25597	66,88793	74,9	71,9	67,8	2523,364486	2726,474288	2787,610619	8,1
40,61544	51,89739	57,12251	70,17667	84,75756	92,15533	72,3	67,9	65,8	2560,547775	2731,87999	2813,489425	7,89
42,68771	52,16516	58,73862	73,93551	87,01507	97,53307	70,1	66,8	64,6	2603,275083	2721,393151	2824,916151	7,98
40,19817	47,50483	54,68771	30,92375	36,21758	42,01786	69,8	66,8	64,3	2604,42783	2697,430346	2827,201594	7,55
36,65011	45,05437	50,59414	59,47476	69,96583	76,95799	69,5	66,4	64,5	2577,113309	2865,188016	2776,889535	7,93

Primeira base de dados do Equipamento Automático

Torque	Altura (mm)	Densidade1(kg/m³)	CondCorr1(uS/m)	DielCorr1	Umidade (%)
1	63,00042	2361,25284	48	1,9	0
2	62,296125	2387,948217	47	2	0
3	61,3761	2423,743454	47	2	0
1	72,65751	2089,740172	47	2,1	2
2	70,087785	2166,359195	47	2,1	2
3	69,034515	2199,411663	47	2,1	2
1	68,64747	1955,658265	46	3,5	4
2	65,037165	2064,219621	45	4	4
3	63,920445	2100,282501	46	4	4
1	64,910265	1950,189259	46	5,9	6
2	61,382445	2062,272065	45	7,1	6
3	59,5995	2123,965832	45	7,7	6
1	62,93697	1969,169023	46	8,3	8
2	59,43453	2085,210933	45	10,1	8
3	57,499305	2155,391822	45	11,1	8
1	67,892415	2021,244679	45	12,2	10
2	63,14001	2173,37917	44	15,8	10
3	61,28727	2239,081338	44	17,2	10
1	68,31753	2119,029553	44	17,9	12
2	63,996585	2262,102971	42	22,9	12
3	62,48013	2317,006464	42	24,7	12
1	67,30233	2185,63331	41	24,2	14
2	63,742785	2307,684145	39	29,4	14
3	61,217475	2402,879477	39	32,7	14
1	68,40636	2320,400599	40	33,9	16
2	65,00544	2441,798082	37	41,2	16
3	63,90141	2483,985232	36	43,6	16
1	70,08144	2144,967635	39	0,8	1
2	68,46981	2195,455495	39	1	1
3	67,25157	2235,225447	39	1	1
1	69,4977	2206,879017	39	2	3
2	68,03835	2254,214217	39	2	3
3	66,699555	2299,460857	39	2,1	3
1	64,70088	1933,884175	39	3,4	5
2	61,19844	2044,56205	39	4,2	5
3	59,51067	2102,547458	39	4,7	5
1	63,9141	1944,108614	39	5,8	7
2	59,54874	2086,626054	39	7,7	7
3	57,778485	2150,557468	39	8,4	7
1	62,8989	1966,02348	39	8,3	9
2	58,641405	2108,76111	38	10,8	9
3	56,6808	2181,703757	38	11,9	9

1	64,161555	2102,440213	37	14,4	11
2	60,468765	2230,834933	36	17,6	11
3	59,0919	2282,814283	36	18,7	11
1	69,745155	2172,734413	36	20,7	13
2	65,849325	2301,27945	35	25,9	13
3	64,516875	2348,807167	35	27,4	13
1	68,780715	2232,768714	36	25,9	15
2	64,33287	2387,137844	34	33,9	15
3	62,651445	2451,203297	32	37,1	15

Segunda Base de dados Equipamento Automático

Er	Er2	Er3	Sigma (uS/m)	Sigma2 (uS/m)	Sigma3 (uS/m)	Altura (mm)	Altura2 (mm)	Altura3 (mm)	DENSID. 1 (kg/m³)	DENSID. 2 (kg/m³)	DENSID. 3 (kg/m³)	Umidade (%)
1,9	2	2	48	47	47	63,00042	62,29613	61,3761	2361,25284	2387,948217	2423,743454	0
0,8	1	1	39	39	39	70,08144	68,46981	67,25157	2122,672146	2172,635219	2211,991789	1
2,1	2,1	2,1	47	47	47	72,65751	70,08779	69,03452	2047,412864	2122,479982	2154,862979	2
2	2	2,1	39	39	39	69,4977	68,03835	66,69956	2140,501349	2186,412819	2230,298547	3
3,5	4	4	46	45	46	68,64747	65,03717	63,92045	2167,012428	2287,306352	2327,266661	4
3,4	4,2	4,7	39	39	39	64,70088	61,19844	59,51067	2299,194704	2430,779618	2499,718465	5
5,9	7,1	7,7	46	45	45	64,91027	61,38245	59,5995	2291,778051	2423,492916	2495,992762	6
5,8	7,7	8,4	39	39	39	63,9141	59,54874	57,77849	2327,497698	2498,120374	2574,659419	7
8,3	10,1	11,1	46	45	45	62,93697	59,43453	57,49931	2363,63334	2502,920788	2587,160325	8
8,3	10,8	11,9	39	38	38	62,8989	58,64141	56,6808	2365,063946	2536,772791	2624,520484	9
12,2	15,8	17,2	45	44	44	67,89242	63,14001	61,28727	2191,112522	2356,03258	2427,256437	10
14,4	17,6	18,7	37	36	36	64,16156	60,46877	59,0919	2318,521124	2460,111772	2517,433365	11
17,9	22,9	24,7	44	42	42	68,31753	63,99659	62,48013	2177,47803	2324,497794	2380,915671	12
20,7	25,9	27,4	36	35	35	69,74516	65,84933	64,51688	2132,906876	2259,095604	2305,75211	13
24,2	29,4	32,7	41	39	39	67,30233	63,74279	61,21748	2210,323486	2333,753077	2430,02379	14
25,9	33,9	37,1	36	34	32	68,78072	64,33287	62,65145	2162,814397	2312,347026	2374,405261	15
33,9	41,2	43,6	40	37	36	68,40636	65,00544	63,90141	2174,650437	2288,42264	2327,959909	16