



Programa de Pós-Graduação em
Computação Aplicada

Mestrado Acadêmico

Régis Cardoso

IoTBio: uma proposta de metodologia para ensaio de
Biodegradabilidade utilizando técnicas de IoT e Aprendizado
de Máquina

São Leopoldo, 2020

Régis Cardoso

**IOTBIO: UMA PROPOSTA DE METODOLOGIA PARA ENSAIO DE
BIODEGRADABILIDADE UTILIZANDO TÉCNICAS DE IOT E APRENDIZADO DE
MÁQUINA**

Orientador:

Prof. Dr. Cristiano André da Costa

Co-orientador:

Prof. Dr. Rodrigo Marques de Figueiredo

São Leopoldo
2020

C268i

Cardoso, Régis.

IoTBio : uma proposta de metodologia para ensaio de biodegradabilidade utilizando técnicas de IoT e aprendizado de máquina / Régis Cardoso. – 2020.

138 f. : il. ; 30 cm.

Dissertação (mestrado) – Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Computação Aplicada, 2020.

“Orientador: Prof. Dr. Cristiano André da Costa

Co-orientador: Prof. Dr. Rodrigo Marques de Figueiredo.”

1. Biodegradabilidade. 2. IoT. 3. Aprendizado de máquina. 4. Sensores. 5. Automação. I. Título.

CDU 007.5

Dados Internacionais de Catalogação na Publicação (CIP)
(Bibliotecária: Amanda Schuster – CRB 10/2517)

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior Brasil (CAPES) - Código de Financiamento 001
This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Finance Code 001

ATA DE BANCA EXAMINADORA DE DISSERTAÇÃO DE MESTRADO Nº 02/2021

Aluno: Régis Cardoso

Título da Dissertação: “IoTBio: UMA PROPOSTA DE METODOLOGIA PARA ENSAIO DE BIODEGRADABILIDADE UTILIZANDO TÉCNICAS DE IoT E APRENDIZADO DE MÁQUINA”

Banca: Prof. Dr. Cristiano André da Costa – Orientador
Prof. Dr. Rodrigo Marques de Figueiredo - Coorientador
Prof. Dr. Claudio Fernando Resin Geyer - UFRGS
Prof. Dr. Victor Gomes - SENAI/RS
Prof. Dr. Rodrigo da Rosa Righi - UNISINOS

Aos vinte e seis dias do mês de fevereiro do ano de 2021, às 14h, a Comissão Examinadora de Defesa de Dissertação composta pelos professores: Prof. Dr. Cristiano André da Costa, Orientador – UNISINOS (participação por webconferência); Prof. Dr. Rodrigo Marques de Figueiredo, Coorientador – UNISINOS (participação por webconferência); Prof. Dr. Claudio Fernando Resin Geyer, Membro da Banca – UFRGS (participação por webconferência); Prof. Dr. Victor Gomes, Membro da Banca – SENAI/RS (participação por webconferência) e Prof. Dr. Rodrigo da Rosa Righi, Membro da Banca – UNISINOS (participação por webconferência), para analisar e avaliar a Dissertação apresentada pelo Régis Cardoso (participação por webconferência).

Considerações da Banca: A banca considera que o trabalho constitui uma dissertação de mestrado. É destacado o caráter aplicado e tecnológico da pesquisa, bem como as contribuições geradas incluindo artigos, patente e melhorias ao serviço oferecido pelo SENAI.

Ocorreu alteração do título? (X) Não () Sim

A Banca Examinadora, em cumprimento ao requisito exigido para a obtenção do Título de Mestre em Computação Aplicada, julga esta dissertação:

(X) APROVADA () REPROVADA

Conforme Artigo 67 do Regimento do Programa o texto definitivo, com aprovação do Orientador, deverá ser entregue no prazo máximo de sessenta (60) dias após a defesa. O resultado da banca é de consenso entre os avaliadores. A emissão do Diploma está condicionada a entrega da versão final da Dissertação. A sessão da Defesa de Dissertação ocorreu integralmente por webconferência para atender às recomendações da OMS e Ministério da Saúde com relação ao Covid-19.

São Leopoldo, 26 de fevereiro de 2021



Prof. Dr. Cristiano André da Costa - Orientador

Dedico esse trabalho aos meus pais: Jairo André Cardoso e Sandra Regina Cardoso, os quais nunca mediram esforços para que eu pudesse estudar e realizar os meus sonhos.

"Muitos são os que deixam pegadas, mas poucos são os que realmente marcam."
— ENZO MENEZES

AGRADECIMENTOS

Em 2010 quando ainda finalizava meu curso técnico, jamais pensava em realizar uma graduação, muito menos um mestrado. É gratificante saber que concluir mais um ciclo da minha vida. Chegar até aqui não seria possível sozinho, então gostaria de agradecer as pessoas que me apoiaram para conclusão do meu mestrado.

Primeiramente agradecer a Deus, pois se não fosse da vontade dele, hoje esse trabalho não estaria concluído.

Aos meus pais os quais nunca mediram esforços para que eu pudesse alcançar todos os meus objetivos e realizar os meus sonhos, sempre me apoiando e servindo de inspiração na vida.

A minha noiva pela paciência e por entender que nem sempre pude estar presente durante esses dois anos.

Aos colegas Guilherme Goldschmidt e Felipe Zeiss, que ao longo dessa jornada acabaram virando grandes amigos, sempre dispostos a conversar, discutir e ajudar nas dificuldades que apareceram ao longo desse tempo.

Ao meu orientador Cristiano André da Costa que foste a primeira pessoa que encontrei dentro do PPGCA, muito obrigado CAC por teres aceitado me orientar e por todas as contribuições, não só nesse trabalho mas nos artigos publicados e submetidos.

Um agradecimento especial ao meu coorientador Rodrigo Marques de Figueiredo, o qual vem me acompanhando desde meu trabalho de conclusão de curso da engenharia, ao longo desses anos se tornou muito mais que um professor, mas sim um grande amigo, sempre pronto para auxiliar, conversar e orientar. Rodrigo tenha certeza que devo muita das coisas boas que aconteceram na minha vida a você, és um exemplo de pessoa e profissional a ser seguido, o meu muitíssimo obrigado.

Ao meu tio Dilson Renato que está sempre disposto a me ajudar e pela segunda vez (a primeira foi no TCC) fez a revisão ortográfica de todo o trabalho.

A CAPES - PROSUP pelo apoio financeiro no desenvolvimento desse trabalho, apoio esse que foi de fundamental importância para possibilitar a realização do curso.

Por fim mas não menos importante gostaria de agradecer ao Instituto Senai de Inovação em Engenharia de Polímeros e a diretora Viviane Lovison, pelo apoio no desenvolvimento desse trabalho e implementação dos protótipos de teste.

RESUMO

Estima-se que até 2050 serão produzidos mais de 500 milhões de toneladas de materiais poliméricos e, se nenhuma ação for tomada, os oceanos terão mais peso em polímeros do que peixes. É com base nessas afirmações que surgem as motivações para realização desse trabalho. Uma solução para redução do acúmulo desses polímeros é a utilização de materiais biodegradáveis, os quais se degradam junto ao meio ambiente. Para determinar o percentual de biodegradabilidade desses materiais, é necessária a utilização de condições padronizadas, através da aplicação de normas e testes de laboratório. Porém, esses testes são longos já que o período de tempo para sua realização varia de 90 a 180 dias. Durante esse tempo é necessário manter um controle preciso sobre as variáveis envolvidas no processo, necessitando de muito envolvimento dos operadores. Sendo assim, o objetivo desse trabalho é a definição de um modelo de equipamento automatizado para determinação do percentual de biodegradabilidade de materiais, utilizando técnicas de Internet das coisas e Aprendizado de máquina. Os trabalhos realizados nesta área não contemplam o desenvolvimento de uma máquina totalmente automatizada, colocando em dúvida a metodologia de controle de umidade dos ambientes de teste. Além disso, não foi encontrado nenhum registro na literatura disponível de protótipos ou equipamentos que utilizem técnicas de Aprendizado de Máquina, tornando esse o grande diferencial da pesquisa realizada nessa dissertação. A proposta tem como objetivo trabalhar em três frentes: avaliação de sensores de baixo custo para aplicações reais, quando foram avaliados diferentes sensores de medição de CO_2 , verificação da efetividade de um controle preciso para umidade do solo, quando se realizou um estudo de diferentes configurações de controle e, por fim, implementação de algoritmos de Aprendizado de Máquina, os quais têm o objetivo de prever resultados do percentual de biodegradabilidade de materiais poliméricos com menos tempo de teste. Nesse âmbito, esta pesquisa propõe o modelo IoTBIO. O IoTBio foi avaliado através da montagem de um protótipo e simulações. Ao final, foi possível verificar que os resultados do percentual de biodegradabilidade de um equipamento automatizado por sensores melhoraram significativamente, quando comparados com os resultados de teste realizados de forma não automatizada. Foram testados algoritmos de ARIMA e de Redes Neurais Recorrentes, mais especificadamente a arquitetura LSTM. Apenas a Rede Neural Recorrente foi capaz de prever valores com erros aceitáveis, porque foram alcançados erros máximos de 13 % entre valores reais e valores previstos para uma execução de apenas 50 dias reais de teste, reduzindo em quase 1/3 o tempo máximo necessário para execução destes ensaios. O desenvolvimento desse trabalho trouxe como principais contribuições o desenvolvimento de um protótipo automático e inteligente que utiliza algoritmos de Aprendizado de Máquina para predição e redução de custos dos testes de biodegradabilidade, através da diminuição do tempo total de ensaio e aplicação de sensores de baixo valor agregado. Os resultados bem-sucedidos desta dissertação resultaram na construção de três equipamentos para determinação do percentual de biodegradabilidade, os quais estão disponíveis para atendimento da indústria e instituições no Instituto Senai de Inovação em Engenharia de Polímeros em São Leopoldo.

Palavras-chave: Automação. IoT. Aprendizado de Máquina. Sensores. Biodegradabilidade.

ABSTRACT

It is estimated that by 2050 more than 500 million tonnes of polymeric materials will be produced and, if no action is taken, the oceans will have more weight in polymers than fish. It is based on these statements that the motivations for carrying out this work emerge. A solution to reduce the accumulation of these polymers is the use of biodegradable materials, which degrade with the environment. To determine the percentage of biodegradability of these materials, it is necessary to use standardized conditions, through the application of standards and laboratory tests. However, these tests are long since the time to perform them varies from 90 to 180 days. During this time it is necessary to maintain a precise control over the variables involved in the process, requiring a lot of involvement from the operators. Therefore, the objective of this work is the definition of an automated equipment model to determine the percentage of biodegradability of materials, using Internet of things and machine learning techniques. The work carried out in this area does not include the development of a fully automated machine, putting in doubt the humidity control methodology of the test environments. In addition, no record was found in the literature available for prototypes or equipment that use Machine Learning techniques, making this the great differential of the research carried out in this dissertation. The proposal aims to work on three fronts: evaluation of low cost sensors for real applications, when different measurement sensors of CO_2 were evaluated, verification of the effectiveness of a precise control for soil moisture, when it was carried out a study of different control configurations and, finally, implementation of Machine Learning algorithms, which aim to predict the results of the biodegradability percentage of polymeric materials with less testing time. In this context, this research proposes the IoTBIO model. IoTBio was evaluated by assembling a prototype and simulations. In the end, it was possible to verify that the results of the percentage of biodegradability of an equipment automated by sensors improved significantly, when compared with the results of tests carried out in a non-automated way. ARIMA and Recurrent Neural Network algorithms were tested, more specifically the LSTM architecture. Only the Recurrent Neural Network was able to predict values with acceptable errors, because maximum errors of 13 % were reached between real values and predicted values for an execution of only 50 real test days, reducing by almost 1/3 the maximum time needed to perform these tests. The development of this work brought as main contributions the development of an automatic and intelligent prototype that uses Machine Learning algorithms to predict and reduce the costs of biodegradability tests, by reducing the total testing time and applying low added value sensors. The successful results of this dissertation resulted in the construction of three pieces of equipment to determine the percentage of biodegradability, which are available to serve industry and institutions at the Senai Institute for Innovation in Polymer Engineering in São Leopoldo.

Keywords: Automation. IoT. Machine learning. Sensors. Biodegradability.

LISTA DE FIGURAS

Figura 1 –	Passos para desenvolvimento da dissertação	22
Figura 2 –	Intersecção das áreas do conhecimento com a automação	25
Figura 3 –	Pirâmide da automação	25
Figura 4 –	Representação da interligação de sistemas de IoT	26
Figura 5 –	Sistemas de IoT 3 e 5 camadas	27
Figura 6 –	Tipo de conexões de redes	28
Figura 7 –	Placa Arduino e Raspberry Pi.	29
Figura 8 –	Estrutura básica sistema de Aprendizado de Máquina	30
Figura 9 –	Fusão das área do conhecimento para Aprendizado de Máquina	31
Figura 10 –	Ciclo para análise dos dados	32
Figura 11 –	Exemplos de distribuição de probabilidade	34
Figura 12 –	Comparação gráfica de média, mediana e moda	34
Figura 13 –	Exemplos de autocorrelação de dados	35
Figura 14 –	Gráfico de exemplo de séries temporais de ensaios do percentual de biodegradabilidade de materiais poliméricos	36
Figura 15 –	Componentes gráficos de uma série temporal	37
Figura 16 –	Exemplo de regressão linear e polinomial	38
Figura 17 –	Neurônios biológico e artificial	40
Figura 18 –	Exemplos de funções de entrada	42
Figura 19 –	Perceptron multicamadas	43
Figura 20 –	Comparação entre rede neural multicamadas e recorrente	43
Figura 21 –	Esquema de funcionamento de uma Rede Neural Recorrente LSTM	44
Figura 22 –	Representação das fases de biodegradabilidade	47
Figura 23 –	Representação de testes de biodegradabilidade pela norma ISO 14855	49
Figura 24 –	Visão geral do modelo IoTBio	64
Figura 25 –	Modelo IoTBio proposto: o modelo é composto de dois grande módulos, o primeiro trata-se do módulo de IoT o qual é composto por sensores e atuadores. O segundo módulo trata-se do módulo de Aprendizado de Máquina, onde são realizados os tratamentos dos dados dos ensaios de biodegradabilidade de materiais poliméricos e aplicação das técnicas de ARIMA e RNA, permitindo a determinação do percentual de biodegradabilidade do material em teste antes do final do tempo real de teste	65
Figura 26 –	Arquitetura proposta para o módulo de IoT	66
Figura 27 –	Fluxo de funcionamento do módulo IoT	68
Figura 28 –	Arquitetura proposta para o módulo de Aprendizado de Máquina	69
Figura 29 –	Demonstração de Funcionamento das previsões	70
Figura 30 –	Fluxo de funcionamento do módulo Aprendizado de Máquina	71
Figura 31 –	Sistemática desenvolvida para testes e medição do sensor de CO_2	75
Figura 32 –	Sensor de umidade do solo	75
Figura 33 –	Sensor de fluxo de ar	76
Figura 34 –	Reatores e câmara de aquecimento projetados e construídos	78
Figura 35 –	Esquema explicativo de um bloco manifold	78
Figura 36 –	Representação da integração entre os sensores e as placas de processamento - A direção das setas representam as saídas e entradas das placas de processamento	79

Figura 37 – Arquitetura geral do módulo de IoT proposto para implementação e avaliação do modelo IoTBio, seguindo o modelo de camadas para sistemas IoT	80
Figura 38 – Protótipo desenvolvido para avaliação do IoTBIO	81
Figura 39 – Sistemas de tolerâncias a falhas	82
Figura 40 – Metodologia de teste para definição do controle de umidade do solo para teste de biodegradabilidade	84
Figura 41 – Exemplo de pré-processamento e entradas de dados	88
Figura 42 – Exemplo de Overtraining, os dados de entrada de uma Rede Neural possuem valores em excesso com um único resultado (100%), deixando a entrada de dados desbalanceada, fazendo com que a rede tenha valores tendenciosos na sua previsão	89
Figura 43 – Dados tomados como base para definição dos parâmetros p, d e q do algoritmo de ARIMA	92
Figura 44 – Esquema de janelamento de uma rede LSTM, considerando um atraso de 5 dias, a rede analisa os 5 últimos valores e prevê o próximo, em seguida verifica a diferença entre valor previsto e real, reajusta os pesos da rede e avança um passo, onde novamente analisa os últimos 5 valores e prevê o próximo, esse loop é realizado até que seja verificado um Overfitting, ou seja, mesmo que reajustados os pesos da rede não existem mais melhoras significativas entre as diferenças dos valores reais e previsos.	93
Figura 45 – Demonstração de avanço de janela de tempo de forma errada e de forma certa, quando é realizada a troca de um polímero para outro o algoritmo deve realizar um "salto" com toda janela de tempo, para que não aconteça interferência dos dados de um polímeros em outro	94
Figura 46 – Comparação entre sensores de CO_2	97
Figura 47 – Resultado final da avaliação do módulo de IoT proposto, no qual é demonstrado claramente que apenas os reatores com controle de umidade por sensores atingiram os valores mínimos esperados para o material padrão, utilizado no teste	101
Figura 48 – Análise dos comportamento dos dados das séries de determinação do percentual de biodegradabilidade de materiais poliméricos, através da decomposição das séries nas componentes: tendência, sazonalidade e resíduo	102
Figura 49 – Representação gráfica da distribuição dos dados de ensaios de biodegradabilidade levantados. O gráfico abaixo mostra um desequilíbrio entre os percentuais de biodegradabilidade, aonde percebe-se uma maior quantidade de ensaios com 100 % de biodegradabilidade para os materiais que já se possui o valor percentual de biodegradabilidade	103
Figura 50 – Resultados para o teste 06 com dados de entrada igual a 50 dias reais	109
Figura 51 – Comparação entre resultados gráficos gerados antes e após a implementação do módulo de IoT. É possível perceber que os dados gerados pelo protótipo automatizado e sensorizado possuem curvas mais estáveis com menor ruído	112

Figura 52 – Resultados para ARIMA com 100 e 80 dias reais de teste, mesmo variando manualmente os valores p, d, q com o passar dos dias, não é possível chegar a um resultado aceitável para justificar a sua utilização no módulo de Aprendizado de Máquina do IoTBio, mesmo quando variamos os parâmetros p, d, q para diferentes amostras	113
Figura 53 – Três equipamentos desenvolvidos com base nos estudos dessa dissertação, foto tirada no Instituto Senai de Inovação em Engenharia de Polímeros - São Leopoldo - Brasil	117
Figura 54 – Sensor de umidade do solo portátil e sensor de análise de gases desenvolvido ao longo dessa dissertação	118
Figura 55 – Mini protótipo desenvolvido com um único reator para participar da feira Mercopar 2020	119
Figura 56 – Certificado do gás padrão utilizado para calibração dos sensores de gás . .	127
Figura 57 – Tabela t de Student	128
Figura 58 – Planilha de calibração do Cromatógrafo	129
Figura 59 – Planilha de calibração Sensor Mhz-14a	130
Figura 60 – Planilha de calibração Sensor LI-820	131
Figura 61 – Planilha de calibração Sensor MQ-135	132
Figura 62 – Planilha de calibração Sensor Umidade do Solo 0%	133
Figura 63 – Planilha de calibração Sensor Umidade do Solo 20%	134
Figura 64 – Planilha de calibração Sensor Umidade do Solo 50%	135
Figura 65 – Planilha de calibração Sensor Umidade do Solo 100%	136
Figura 66 – Planilha de calibração Sensor de Fluxo 100 mL/min	137
Figura 67 – Planilha de calibração Sensor de Fluxo 400 mL/min	138
Figura 68 – Planilha de calibração Sensor de Fluxo 600 mL/min	139

LISTA DE TABELAS

Tabela 1 –	Comparação entre os trabalhos relacionados. Percebe-se uma diversidade de parâmetros para as atuais metodologias de teste automatizado desenvolvidas. Nenhuma dessas metodologias utilizam o controle de umidade do solo por sensores e atuadores de forma automática. (NA - Não aplicado ou não especificado pelos autores)	54
Tabela 2 –	Comparação entre os trabalhos relacionados. Os trabalhos mostram as principais métricas de avaliações utilizada para previsão de séries temporais, além de apontar ARIMA e RNA como o estado da arte no que diz respeito a previsão de séries temporais	59
Tabela 3 –	Desvio padrão dos sensores de CO_2 , o desvio padrão foi calculado para uma amostra de 31 medições ($n = 31$)	98
Tabela 4 –	Calibração sensor de umidade do solo capacitivo, o desvio padrão foi calculado para uma amostra de 10 medições ($n = 10$)	99
Tabela 5 –	Calibração sensor de fluxo de ar, o desvio padrão foi calculado para uma amostra de 10 medições ($n = 10$)	99
Tabela 6 –	Teste de homogeneidade, o desvio padrão foi calculado para uma amostra de 30 medições ($n = 30$)	100
Tabela 7 –	Medição de umidade para avaliação do controle de umidade do modelo ao final dos 45 dias de teste, o desvio padrão foi calculado para uma amostra de 3 medições ($n = 3$)	100
Tabela 8 –	Parâmetros utilizados nos testes de otimização de (p,d,q) do ARIMA, não foram encontrados parâmetros que resultassem em um valores baixos de erros entre valores reais e previstos, essa avaliação será descrita no capítulo de discussão dos resultados, valores médios calculados para uma amostra de 3 medições ($n = 3$)	105
Tabela 9 –	Parâmetros utilizados nos testes de otimização da rede neural, os dados em negrito representam os melhores resultados alcançados para os parâmetros de MAE, MSR, RMS e RMSE para polímeros com percentual de biodegradabilidade máximos de 40 %, 100%, e 80%, valores médios calculados para uma amostra de 3 medições ($n = 3$)	107
Tabela 10 –	Avaliação da acurácia para 30, 40, 50, 60, 70 e 80 dias de teste real já ocorrido, a partir de 40 dias reais de teste o algoritmo já tem capacidade de fazer previsões com erro percentual aceitável. Os erros reduzem gradativamente conforme os dias reais de teste aumentam, valores médios calculados para uma amostra de 3 medições ($n = 3$)	110

LISTA DE SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
IoT	Internet das Coisas do inglês: Internet of Things
AM	Aprendizado de Máquina
AI	Inteligência Artificial do inglês: Artificial Intelligence
MAE	Erro Médio Absoluto do inglês: Mean Absolute Error
MSE	Erro Médio Quadrático do inglês: Mean Squared Error
RMSE	Raiz quadrada do Erro Médio do inglês: Root Mean Square Error
MAPE	Erro Médio Absoluto Percentual do inglês: Mean Absolute Percentage Error
ARIMA	Média Móvel Integrada Autorregressiva do inglês: Autoregressive Integrated Moving Average
RNA	Rede Neural Artificial
LSTM	Memória de Longo Prazo do inglês: Long Short-Term Memory
ASTM	Sociedade Americana de Testes e Materiais do inglês - American Society for Testing and Materials
ISO	Organização Internacional de Normas do inglês: International Organization for Standardization
IoTBio	Modelo proposto por essa dissertação, composto por módulo de IoT e módulo de Aprendizado de Máquina

SUMÁRIO

1	INTRODUÇÃO	17
1.1	Motivação	19
1.2	Questão de pesquisa	20
1.3	Objetivos	21
1.4	Conquistas	22
1.5	Organização textual	23
2	REFERENCIAL TEÓRICO	24
2.1	Automação	24
2.2	Industria 4.0	26
2.2.1	Internet das Coisas	27
2.3	Inteligência Artificial	30
2.3.1	Aprendizado de Máquina	30
2.3.2	Análises estatísticas	33
2.3.3	Técnicas de Aprendizado de Máquina	37
2.4	Desintegração Acelerada de Materiais Poliméricos – Biodegradabilidade	45
2.4.1	Normatização	48
3	TRABALHOS RELACIONADOS	50
3.1	Metodologia de pesquisa e seleção de trabalhos	50
3.2	Análise dos trabalhos para metodologias automatizadas	51
3.2.1	Comparação entre trabalhos	53
3.3	Análise dos trabalhos para predição de séries temporais	55
3.3.1	Comparação entre trabalhos	58
3.4	Considerações parciais	61
4	MODELO PROPOSTO: IoTBIO	63
4.1	Decisões de Projeto	63
4.2	IoTBio	65
4.2.1	Módulo IoT	65
4.2.2	Módulo de Aprendizado de Máquina	69
5	MATERIAIS E MÉTODOS	73
5.1	Protótipo de Hardware Desenvolvido	73
5.1.1	Seletividade de Sensores	73
5.1.2	Reatores e Câmara de Aquecimento	77
5.1.3	Válvulas	78
5.1.4	Integração entre sensores	79
5.1.5	Tolerância a falhas	81
5.1.6	Configuração de teste do protótipo, avaliação do módulo de IoT	83
5.1.7	Visualização dos dados	86
5.2	Implementação do Módulo de Aprendizado de Máquina	86
5.2.1	Pré-processamento dos dados	87
5.2.2	Algoritmos de Aprendizado de Máquina - Predição	90

6	RESULTADOS E DISCUSSÃO	97
6.1	Avaliação dos sensores	97
6.1.1	Sensor de CO_2	97
6.1.2	Sensor de umidade do solo	98
6.1.3	Sensor de medição de fluxo de ar	99
6.1.4	Sensor de Temperatura	99
6.1.5	Avaliação geral do módulo de IoT	99
6.2	Predição de resultados	101
6.2.1	Análise dos dados	101
6.2.2	Pré-processamento	103
6.3	Discussão dos resultados	111
7	CONCLUSÃO	116
7.1	Contribuições	117
7.2	Trabalhos futuros	118
	REFERÊNCIAS	120
	ANEXO A	127
	ANEXO B	128
	ANEXO C	129
	ANEXO D	130
	ANEXO E	131
	ANEXO F	132
	ANEXO G	133
	ANEXO H	134
	ANEXO I	135
	ANEXO J	136
	ANEXO K	137
	ANEXO L	138
	ANEXO M	139

1 INTRODUÇÃO

A área de Materiais Poliméricos cresceu muito. Nos últimos 50 anos, os plásticos estão substituindo materiais como papel, madeira e metal (LUYT; MALIK, 2019). O grande problema dos materiais poliméricos é o seu acúmulo, devido à dificuldade de degradação no meio ambiente (YIN; YANG, 2020). Hoje, infelizmente, a produção de polímeros sintéticos possui uma estrutura linear unidirecional que consiste na remoção de matérias-primas do ambiente, fabricação, uso e descarte, o que resulta no acúmulo de 95 % em aterros e oceanos a cada ano. Se nenhuma ação for tomada até 2050, os oceanos terão mais peso nos materiais poliméricos do que nos peixes (HONG; CHEN, 2019). Assim, surgem novas preocupações com relação ao descarte e o que fazer após a utilização destes materiais. Esta questão tem feito com que empresas e organizações procurem por novas alternativas para reduzir os riscos ambientais. Portanto, estudos com materiais de maior facilidade de decomposição tiveram crescimento (SILVEIRA et al., 2019). Polímeros biodegradáveis são aqueles que se degradam naturalmente através da presença de micro organismos como bactérias e fungos (D883-20, 2019). Quando um material específico entra no processo de decomposição, ocorre a interação dos organismos, transformando a matéria-prima em dióxido de carbono (CO_2). Medindo a emissão de CO_2 e usando cálculos matemáticos, é determinada a porcentagem de biodegradabilidade. Algumas normas nacionais e internacionais podem ser utilizadas para determinar a biodegradabilidade de materiais poliméricos, simulando solos e ambientes marinhos (oceanos) (RUGGERO; GORI; LUBELLO, 2019).

Todos os avanços no desenvolvimento de materiais fizeram com que máquinas e equipamentos também precisassem de sistemas avançados, proporcionando maior produtividade e precisão nas operações. Com isso, em 1999, o conceito de IoT - Internet das Coisas, foi introduzido (MADAKAM et al., 2015). A IoT surgiu principalmente devido à necessidade de conectar várias "coisas" através do uso da Internet, tornando os processos mais eficientes e seguros devido à coleta de informações por diversos sensores (CORRAL-PLAZA et al., 2020). Com a expansão dos sistemas de IoT em 2011, por meio de uma estratégia do governo alemão, surgiu o conceito de Indústria 4.0 (KAGERMANN et al., 2016). A multiplicidade de interconexão entre tecnologias como sistemas embarcados, controle distribuído e big data são características da indústria 4.0 (PACCHINI et al., 2019). Portanto, a IoT e a indústria 4.0 vêm sendo aplicados continuamente para aprimoramento de processos e com isso diariamente surgem novos sensores para diferentes aplicações, tornando as máquinas e equipamentos cada vez mais independentes e inteligentes. A aplicação dessas técnicas reduz o tempo de intervenção humana, aumentando a produtividade, confiabilidade e o controle de uma grande quantidade de dados que servirão na futura tomada de decisões (XU; DUAN, 2019).

Tomando como base o avanço da tecnologia e o desenvolvimento de novos materiais, esta dissertação descreve um modelo denominado IoTBio, o qual trata de uma proposta de

metodologia de teste automatizado e autônomo para determinação do percentual de biodegradabilidade de materiais. Os tempos de testes de biodegradabilidade são longos, variando entre 90 e 180 dias, fazendo com que seja necessário um controle minucioso das variáveis envolvidas no processo. Estes longos tempos acabam por limitar a realização dos ensaios, tornando o tempo de resposta para a avaliação de novos materiais lento, o que prologa os tempos de espera entre um ensaio e outro, além de trazer toda complexidade da massiva interação entre o operador para garantir os parâmetros do ensaio. Sendo assim, o IoTBio é composto por dois grandes grupos: o primeiro diz respeito à sensorização e automação de um protótipo para garantir o correto controle das variáveis envolvidas no processo, e o segundo aquele em que foram aplicadas as técnicas de Aprendizado de Máquina para previsão de resultados antes do tempo total de ensaio.

Foi desenvolvido um protótipo que serviu para avaliação dos conceitos aplicados, possibilitando a coleta de dados. Estes dados foram utilizados para implementação de algoritmos de ARIMA e Redes Neurais Artificiais – RNA. A intenção da aplicação destes algoritmos está na previsão de resultados futuros, uma vez que os testes reais da determinação do percentual de biodegradabilidade ocorrem em longos períodos de tempo, os quais variam entre 90 e 180 dias. O desenvolvimento destes dois algoritmos permitiu a avaliação de qual a melhor metodologia de predição deve ser adotada. A implementação possibilitou a previsão dos testes com períodos entre 40 e 50 dias reais de teste com erros justificáveis e aceitáveis.

Inicialmente, foram pesquisados equipamentos similares já desenvolvidos e sensores de baixo custo disponíveis no mercado. Os sensores selecionados foram testados e instalados em um protótipo preliminar para avaliação do modelo IoTBio. O protótipo foi utilizado para avaliação e seleção da melhor metodologia a ser usada no equipamento final. Os testes realizados fazem uma comparação entre os métodos atuais, usados para controlar a umidade do solo, e as novas técnicas através da aplicação de sensores. Esta comparação demonstrará que o controle de umidade por sensores é mais eficaz na realização de testes de biodegradabilidade, além dos novos resultados disponibilizados pelo equipamento automatizado serem mais estáveis, devido a poucas intervenções dos operadores com o teste.

Os dados resultantes dos testes do percentual de biodegradabilidade tratam-se de dados temporais, ou seja, valores que são registrados ao longo do tempo, o que chamamos estes dados de séries temporais. As séries temporais possuem três componentes os quais podem ser decompostas dessas séries: sazonalidade, tendência e resíduo. Porém, no decorrer desta dissertação foi possível perceber que os dados, resultantes dos ensaios de biodegradabilidade, não possuíam a componente sazonal. Isso fez com que fossem necessárias algumas manipulações diferentes, uma vez que classificamos estes dados como séries comportamentais.

Muitos são os resultados de ensaios laboratoriais em materiais poliméricos que possuem características similares aos testes do percentual de biodegradabilidade, ensaios como tração, rasgamento, relaxação de stress, compressão entre outros. Com isso, a principal contribuição científica deste trabalho está na proposição de um modelo baseado em IoT e Aprendizado de

Máquina, no qual os algoritmos implementados servirão de base para previsão de resultados destes outros tipos de testes.

1.1 Motivação

É gratificante utilizar a ciência e tecnologia a favor da sociedade para desenvolvimento de novos produtos e tecnologias que irão melhorar a vida das pessoas. Porém, é necessário levar em consideração os resultados negativos que estes desenvolvimentos podem vir a gerar no futuro. Com o crescimento demasiado das pesquisas dos materiais poliméricos é natural que a sua utilização seja cada vez maior. Logo, é importante saber qual o destino correto após o seu período de utilização.

De acordo com (YIN; YANG, 2020), até 2050, estima-se que serão produzidos mais de 500 milhões de toneladas de materiais poliméricos, o que é um grande problema para o meio ambiente, uma vez que estes polímeros tendem a se acumular ao invés de se biodegradarem junto ao ambiente. Dessa forma, os estudos e desenvolvimento de materiais poliméricos biodegradáveis têm aumentado, devido à ineficácia dos métodos tradicionais de descarte dos polímeros convencionais. Atualmente existem alguns métodos para eliminação de resíduos poliméricos como incineração e reciclagem mecânica, porém estes métodos possuem limitações, dificultando a sua efetivação (CINELLI et al., 2019). Dessa forma, a metodologia de descarte mais adequada seria a de desintegração natural, reduzindo assim os riscos ambientais gerados por estes resíduos (SILVEIRA et al., 2019). Para que esta desintegração natural ocorra, é necessário que o material poliméricos seja biodegradável (D883-20, 2019). Um polímero só pode ser classificado como biodegradável quando submetido a ensaios normatizados. Estes ensaios são feitos em escala laboratorial e devem possuir um controle rigoroso sob as variáveis envolvidas nestes testes.

Foram evidenciados alguns gaps no desenvolvimento de protótipos automatizados para realização de ensaios de biodegradabilidade. Porém, os modelos propostos por outros autores não utilizaram técnicas específicas e, por consequência, os sistemas não eram totalmente automáticos, sendo suscetíveis a falhas. Além disso, os sistemas não contemplam um controle sensorizado sobre a umidade do solo dos compostos, controle este que é demonstrado nesta dissertação que tem fundamental importância na realização dos testes de biodegradabilidade.

Diante do exposto, o modelo IoTBio utilizará técnicas de Internet das Coisas – IoT, trazendo uma vasta integração de sensores e atuadores, tornando possível a automatização, aquisição e gerenciamento dos dados pertinentes aos ensaios de biodegradabilidade, o que não é visto nos testes atuais, massivamente dependentes dos operadores, o que traz toda a complexidade de possíveis erros devido a medidas intrusivas pela interação do operador com o teste. Após a implementação automatizada, será possível a coleta de dados de ensaios, possibilitando o desenvolvimento de técnicas de Aprendizado de Máquina, para predição de resultados, item este que também não é evidenciado em nenhuma pesquisa na área de testes de

biodegradabilidade, o que vai redefinir os tempos necessários para os testes de meses para dias. Sendo assim, a principal motivação para desenvolvimento desse trabalho é unir ciência, tecnologia e normas técnicas para o desenvolvimento do modelo IoTBio, trazendo uma nova metodologia de teste/ensaio para determinação da biodegradabilidade de materiais de forma automática e inteligente, reduzindo os possíveis erros das intervenções dos testes com operadores, além de proporcionar a realização de testes em tempo reduzido, devido à aplicação de algoritmos de Aprendizado de Máquinas, permitindo de forma ágil, confiável e com baixo custo a avaliação de novos materiais desenvolvidos por empresas e organizações.

1.2 Questão de pesquisa

Este trabalho busca responder a seguinte questão de pesquisa:

Como seria um modelo para desenvolvimento de testes de Biodegradabilidade de materiais poliméricos, que trabalhe de forma autônoma, inteligente e com baixo custo utilizando técnicas de predição para redução dos tempos de teste?

Para responder o questionamento acima, é necessário explorar um pouco cada um dos termos utilizados:

- **Biodegradabilidade:** trata-se do fenômeno no qual os materiais se degradam naturalmente devido à interação de fungos e bactérias (D883-20, 2019). A presença destes microrganismos faz com que seja gerado dióxido de carbono (CO_2) e, com base em fórmulas matemáticas, é possível calcular e determinar qual é o percentual de biodegradabilidade de materiais, quando submetidos a condições de temperatura, umidade e fluxo de ar controlados;
- **Autônoma:** sistemas robóticos e de automação são estudados desde 1980. Estas pesquisas visam à utilização de meios computacionais para realização de trabalhos autônomos, sistemas autônomos que possuem características técnicas para melhorar a qualidade e eficiência das operações e, conseqüentemente, reduzir custos na operação e recursos utilizados. Os sistemas autônomos podem trabalhar sob visão de um supervisor humano ou sem nenhuma interação humana (ARDINY; WITWICKI; MONDADA, 2015);
- **Sistemas inteligentes:** muito tem se falado em sistemas inteligentes os quais estão associados a características humanas como compreensão, aprendizado e raciocínio (MELLIT; KALOGIROU, 2008). No caso desta dissertação, diz-se que o sistema implementado deve ser inteligente a ponto de executar o monitoramento e leitura de todos os sensores através da aplicação de algoritmos computacionais. Além disso, o sistema deve sinalizar aos operadores quando da eventualidade de uma falha;

- **Baixo custo:** a relação de custo no desenvolvimento desta pesquisa está em duas partes. A primeira na seleção de sensores, quando foi buscado por sensores de baixo custo que atendessem as tolerâncias de medição. A segunda no que diz respeito à redução dos tempos reais de testes, através da aplicação das técnicas de Aprendizado de Máquina para previsão dos resultados, uma vez que um longo período de ensaio está diretamente ligado a consumo de energia elétrica, envolvimento técnico e lentidão na aprovação de um novo produto biodegradável desenvolvido;
- **Técnicas de predição:** diversas são as áreas que utilizam técnicas de previsões como previsões meteorológicas, previsões de demanda de sistemas de energia, previsões de falhas, entre outros. O estudo destas predições está associado a um grande banco de dados, os quais, através da aplicação de algoritmos computacionais, possibilitam a verificação de eventos futuros nas mais diversas áreas. As técnicas de previsão são muito utilizadas na verificação de falhas ou eventos futuros, porém, no caso desta dissertação, elas são utilizadas na previsão dos resultados finais do percentual de biodegradabilidade, reduzindo, consequentemente, os tempos de ensaios.

Definidos os termos utilizados na questão de pesquisa, é possível entender que esta dissertação tem como objetivo o estudo de um modelo para desenvolvimento de ensaios de Biodegradabilidade, o qual deve trabalhar durante todo o ensaio sem a intervenção humana, possibilitando seu acompanhamento remoto, o qual reporte ao operador/usuário à eventualidade de alguma anomalia em seu funcionamento. Além disso, o modelo deve permitir a aplicação de algoritmos de predição. Esta aplicação tem como principal objetivo a redução de tempo de ensaios. A ideia é prever o percentual de biodegradabilidade dos materiais testados, utilizando tempos inferiores a estes, o que, consequentemente, resultará na redução de custos de insumos como energia elétrica, ar comprimido e água.

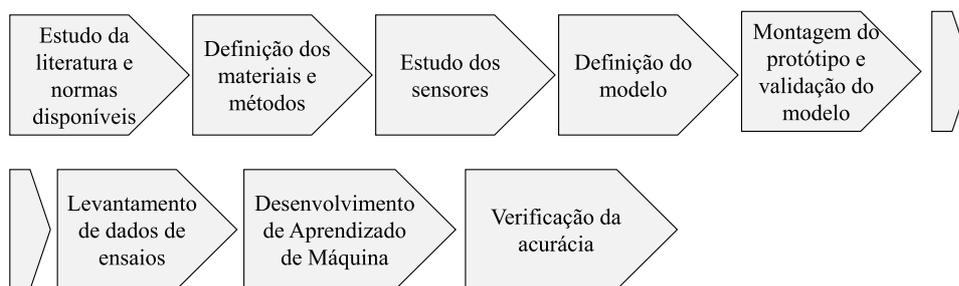
Para desenvolvimento do modelo proposto será necessário um levantamento de características e funcionamento de sensores de baixo custo, para aplicação e avaliação de um protótipo a ser desenvolvido. Além disso, será necessária a aplicação de técnicas de IoT e Aprendizado de Máquina como ARIMA, Redes Neurais e Análises Estatísticas, combinadas com plataformas de prototipagem, software de Aprendizado de Máquina e dashboards.

1.3 Objetivos

O objetivo principal deste trabalho é a definição de um modelo a ser utilizado na implementação de ensaios de biodegradabilidade de forma autônoma e inteligente. Com isso, a Figura 1 mostra os passos seguidos para atingir os principais objetivos desta dissertação.

O modelo desenvolvido é denominado como IoTBio. A avaliação do IoTBio será realizada através do desenvolvimento de um protótipo automatizado, inteligente e de baixo custo. O protótipo deve operar de forma autônoma, possibilitando a aquisição de dados que serão

Figura 1: Passos para desenvolvimento da dissertação



Fonte: elaborado pelo autor

utilizados na aplicação de técnicas de Aprendizado de Máquina para previsão dos valores percentuais da biodegradabilidade das amostras em teste, sem a necessidade da realização do período completo de teste. O período completo e real destes testes pode variar de 90 a 180 dias. A proposta é utilizar ARIMA e Redes Neurais Artificial LSTM e reduzir este tempo através de previsões realizadas com base em polímeros já testados.

1.4 Conquistas

A principal contribuição científica deste trabalho está na proposição de um modelo baseado em IoT e Aprendizado de Máquina. Durante a realização do trabalho, foram realizadas uma submissão de artigo, uma publicação e um registro de patente:

- Submissão de um artigo junto à revista Computer Standards and Interfaces em maio de 2020. O artigo descreve as etapas de implementação e avaliação de um modelo para testes de biodegradabilidade automatizado. A proposta visa definir a melhor metodologia para a realização de testes de desintegração de materiais com a finalidade de examinar a porcentagem de sua biodegradabilidade;
- Publicação de um artigo junto ao Congresso Brasileiro de Automática o CBA, em novembro de 2020, o maior congresso de Engenharia Elétrica do Brasil desde 1976. O artigo publicado teve como objetivo a definição de um modelo de equipamento automatizado para determinação do percentual de biodegradabilidade de materiais, utilizando técnicas de Internet das coisas e Aprendizado de Máquina. Durante o evento o trabalho foi elogiado pelos participantes, os quais parabenizaram os resultados obtidos para a implementação dos algoritmos de Aprendizado de Máquina para previsão dos testes;
- Depósito de patente para o equipamento desenvolvido ao longo desta dissertação em novembro de 2020. A patente teve como objetivo proteger o equipamento e método automatizado para determinação da biodegradabilidade de materiais em escala laboratorial, desenvolvido ao longo deste trabalho.

1.5 Organização textual

Esse trabalho está organizado em 6 seções. O capítulo 2 descreve conceitos necessários para o entendimento da implementação proposta onde serão definidos conceitos como: automação, IoT, análises estatísticas, séries temporais e Aprendizado de Máquina. O capítulo 3 faz uma apresentação de trabalho relacionados que foram encontrados na literatura, mostrando uma comparação e descrevendo quais os diferenciais entre esta dissertação e os trabalhos desenvolvidos por outros pesquisadores. No capítulo 4 é definido o modelo IoTBio, fazendo a descrição das decisões de projetos e características do modelo. Logo após a definição do modelo, no capítulo 5, foram selecionados os materiais e métodos, definindo cada um dos materiais e a forma de aplicação dos mesmos. O capítulo 6 mostra os resultados da implementação do modelo e os resultados alcançados para as técnicas de IoT e Aprendizado de Máquina, bem como os pontos positivos e limitações. Por fim, serão apresentadas as conclusões sobre os resultados alcançados, as contribuições científicas e tecnológicas e os trabalhos futuros.

2 REFERENCIAL TEÓRICO

Nesse capítulo serão apresentados os conceitos necessários para o entendimento da implementação do IoT BIO destinado a testes de biodegradabilidade em materiais poliméricos. Ao final será possível compreender cada uma das tecnologias hoje disponíveis que podem ser utilizadas no desenvolvimento dessa proposta de mestrado. Este capítulo está organizada em três partes, a primeira abrange os conceitos e a evolução dos sistemas de automação, o segundo trata-se das técnicas de Aprendizado de Máquina - AM, do inglês Machine Learning e suas aplicações, a terceira parte apresenta algumas das normas que fazem referência a operacionalização de testes de biodegradabilidade aplicado a materiais poliméricos.

2.1 Automação

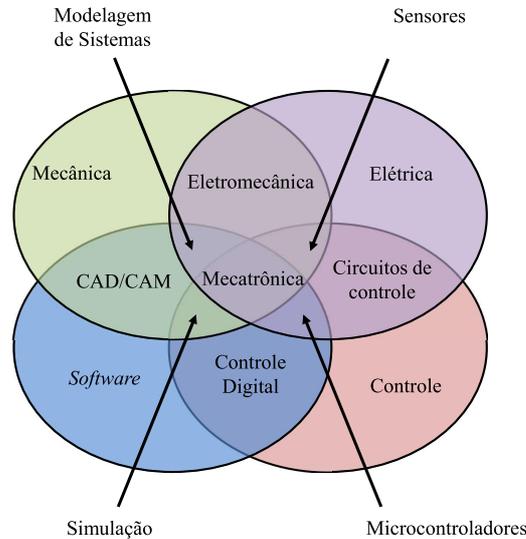
Desde o século XVIII a indústria vem sofrendo constantes revoluções, a primeira é marcada pela utilização do vapor como fonte de energia, na segunda revolução passou-se a utilizar a energia elétrica e preocupava-se com o aumento da produtividade através de linhas de produção, já a terceira revolução utilizava recursos computacionais e manufatura (MUHURI; SHUKLA; ABRAHAM, 2019). No final do século XIX, a mecanização da produção foi plenamente consolidada e com isso iniciou o surgimento dos primeiros sistemas automatizados. Podemos entender como Automação, toda e qualquer atividade destinada a reduzir o esforço físico do ser humano, os processos automatizados podem ser resumidos como: uma ou um conjunto de máquinas supervisionadas por um único operador, uma série de máquinas em linha para realização de processos diferentes, conjunto de máquinas que realizam uma sequência de operações, sistemas de montagem automatizados, robôs industriais, sistemas automáticos de inspeção, embalagens e controle automático de variáveis de processos (FILIPPO, 2014). Todo processo automatizado é classificado em dois grandes grupos:

- Malha fechada: configuração caracterizada pela existência de uma ou mais realimentações em sua saída, onde o sinal de controle é realimentado e comparado com a referência da entrada, interligando a diferença entre o sinal de entrada e o de saída para toda a malha, com a finalidade de correção de erros para um controle preciso.
- Malha aberta: sistema que possuem um caminho direto desde sua entrada até a sua saída, sem realimentação, nesse caso o sinal de saída não é medido, sendo necessária a utilização de técnicas específicas para se manter um controle preciso.

Com a evolução da Automação, surgiram os Sistemas de Automação, os quais possuem um conceito ainda mais amplo, sofrendo influência de várias áreas do conhecimento aplicadas em um grande conjunto de técnicas de controles.

Pode-se dizer que um sistema de automação possui cinco níveis, a chamada pirâmide da automação, classifica cada um desses níveis atribuindo funções conforme demonstrado na

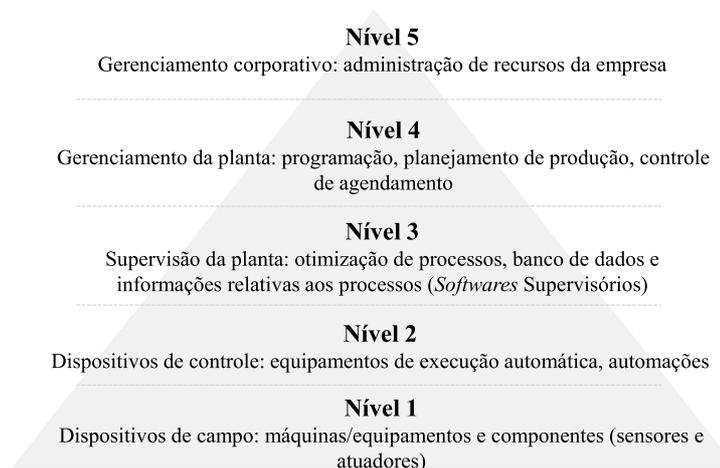
Figura 2: Intersecção das áreas do conhecimento com a automação



Fonte: elaborado pelo autor

Figura 3, nessa imagem é possível perceber que a automação ou os sistemas de automação não estão ligados somente a máquinas e equipamentos, mas também a um processo de produção completo, que vai desde o sensores até os softwares de gerenciamento de recursos financeiros e matéria prima (MIKELL, 2011).

Figura 3: Pirâmide da automação



Fonte: adaptado de (MIKELL, 2011)

Nesse cenário percebe-se que existe a integração de uma série de técnicas, dispositivos e softwares, os quais são interligados que trabalham em conjunto com a finalidade de centralizar informações e auxiliar na tomada de decisões. A utilização demasiada de recursos computacionais e aumento da produtividade, forçou o desenvolvimento de uma quarta revolução, em 2011, através de uma iniciativa do governo Alemão, essa revolução foi denominada de Industria 4.0 e a partir de então a revolução não é mais referida exclusivamente a indústria, mas sim uma revolução geral integrando indústrias, residências e o cotidiano das

peças (MUHURI; SHUKLA; ABRAHAM, 2019).

2.2 Indústria 4.0

Kagermann et al. (2011) descreve que a quarta revolução industrial integra ambientes virtuais com os reais, processos de simulação, sensores e atuadores serão interligados a uma rede de Internet, máquinas conversarão com sistemas computacionais e ajudarão pessoas na tomada de decisões, processos passam agora por serem robotizados e automatizados, disponibilizando dados de forma centralizada em painéis de controle, a partir essa revolução industrial a preocupação não está apenas na produção em massa, mas também com o aproveitamento de matéria prima, tempo de vida de produto e qualidade ambiental (KAGERMANN; LUKAS; WAHLSTER, 2011). Para Aileni et al. (2020) o conceito de Indústria 4.0 é representado por fábricas inteligentes, onde sensores e atuadores são interconectados através da IoT – Internet of Things, do inglês, Internet das Coisas, processando uma grande quantidade de dados de forma inteligente, disponibilizando informações para outros equipamentos e pessoas (AILENI et al., 2020).

Figura 4: Representação da interligação de sistemas de IoT



Fonte: elaborado pelo autor

Podemos entender o conceito de Indústria 4.0 como um grande apanhado de técnicas que buscam a simulação, planejamento, produção e rastreabilidade, facilitando controle de toda a vida de um produto até o seu descarte (FRANK; DALENOGARE; AYALA, 2019). Para que seja possível atender os requisitos da Indústria 4.0, são necessárias a aplicação de várias metodologias de controle, processamento e distribuição de dados, dessa forma a internet passou a ser o meio que faz a conexão entre todos esses sensores, softwares e dispositivos, surgindo então o que chamamos de Internet das Coisas, que será descrita na próxima seção.

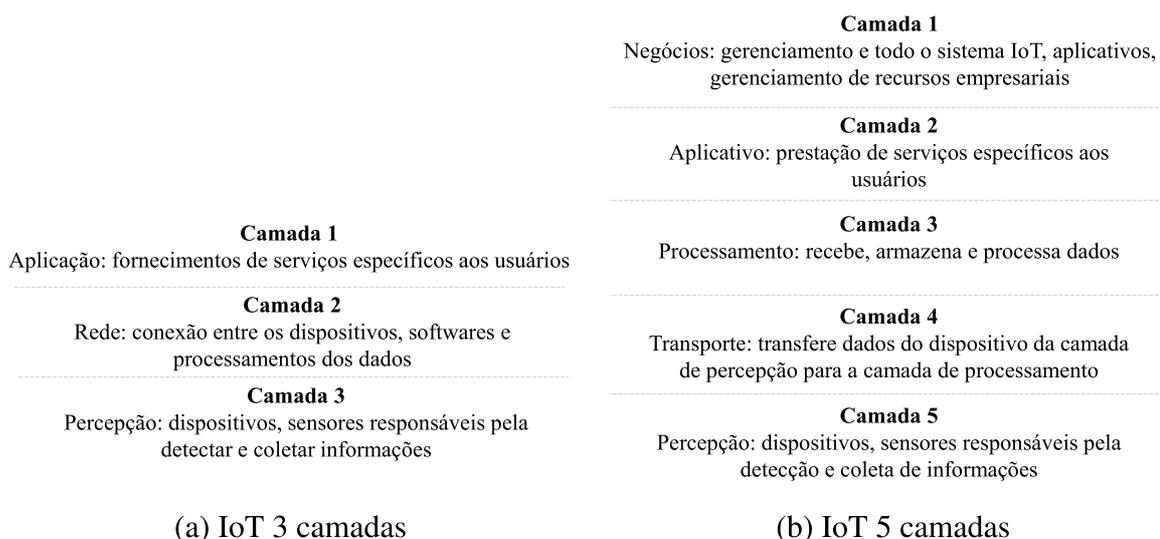
2.2.1 Internet das Coisas

Com os processos automatizados crescendo exponencialmente, foram surgindo novas técnicas e conceitos para as mais diversas aplicações, a Internet das Coisas ou somente IoT, faz a fusão entre o mundo real e o mundo digital. IoT não é aplicada apenas a sensores e atuadores, mas também dispositivos móveis, softwares de coleta e bancos de dados, processamento e extração de informações relevantes aos mais diversos processos, máquinas e equipamentos (YAN; ZHANG; VASILAKOS, 2014).

(KOUICEM; BOUABDALLAH; LAKHLEF, 2018) descreve que em IoT os sensores, atuadores, dispositivos e softwares, são classificados como as “coisas” que compõem um processo ou equipamento, permitindo que os indivíduos estejam em constante comunicação e interação seja entre pessoas e “coisas” ou somente entre “coisas”, entende-se assim que existe uma grande junção de “coisas” físicas e digitais as quais passam a aprender e se tornarem cada vez mais inteligentes, devido a possibilidade de acesso a uma grande quantidade de dados.

Alguns pesquisadores descrevem que não é possível definir uma arquitetura universal para IoT, devido a exclusividade de cada aplicação. Para (RAY, 2018) a arquitetura IoT pode ser física, virtual, híbrida ou ambos juntos, os quais compõem vários serviços em nuvem, protocolos IoT específicos, camadas de comunicação, usuários, desenvolvedores e camada corporativa. Outros pesquisadores descrevem que IoT possui uma arquitetura definida por três ou cinco camadas, as quais são muito similares com os níveis da pirâmide da automação (SETHI; SARANGI, 2017).

Figura 5: Sistemas de IoT 3 e 5 camadas



Fonte: adaptados de (SETHI; SARANGI, 2017)

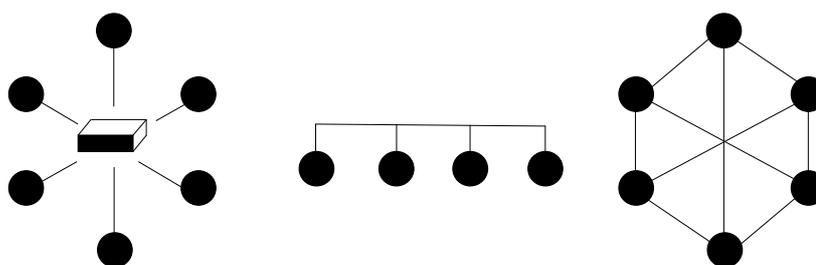
Percebe-se que a arquitetura de um sistema de IoT com cinco camadas é muito semelhante aos sistemas de automação visto anteriormente, porém agora é possível trabalhar com uma grande quantidade de dados e informações, além disso, em uma rede IoT as máquinas e

equipamentos não apenas fornecem informações para tomadas de decisão dos usuários, mas também comunicam-se entre si e entre qualquer tipo de dispositivos, seja um computador ou um smartphone, possuindo capacidade de processamento inteligente, através da aplicação de algoritmos específicos.

Os sistemas de IoT necessitam de sensores e atuadores para aquisição de dados nos ambientes físicos esses dispositivos pertencem a Camada de Percepção, hoje é possível verificar uma grande quantidade de dispositivos fabricados para essas funções, desde os mais simples sensores (os quais detectam apenas uma variável) até os mais complexos (os quais detectam mais variáveis e ainda possuem capacidade de filtro de informações) (SETHI; SARANGI, 2017).

Para interligação dos sensores e atuadores são necessários redes e protocolos de comunicação os quais fazem parte da Camada de Transporte. As Redes podem ser classificadas em três categorias: estrela, ponto a ponto e malha. A primeira a conexão é feita entre os dispositivos da rede, na segunda os dispositivos são conectados através de um hub central, já na terceira todos os nós são interligados entre si (YAQOOB et al., 2017). Mesmo que a arquitetura de uma rede possa parecer física, por meio de cabos é importante lembrar que também existem as redes com acesso sem fio. Além de redes são necessários protocolos de comunicação, esses são importantes para que seja possível a conexão entre sensores, atuadores, dispositivos e softwares, pode-se assimilar os protocolos de comunicação como o idioma com que todos os componentes da rede irão se comunicar.

Figura 6: Tipo de conexões de redes



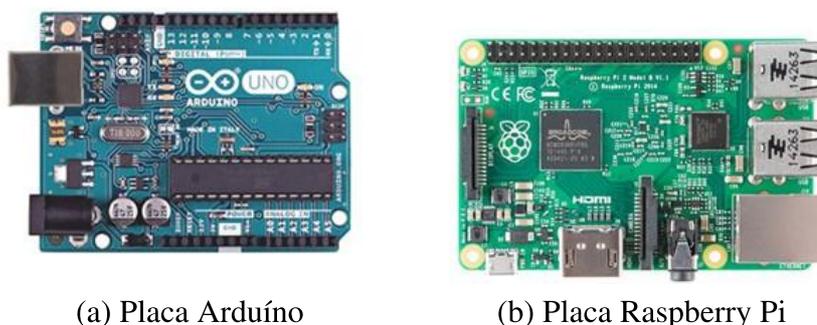
Fonte: adaptado de (YAQOOB et al., 2017)

Nos ambientes industriais existem alguns protocolos já consolidados os quais devem ser selecionados levando em consideração alguns itens como: fluxo de dados, distancias entre dispositivos, infraestrutura disponível e capacidade de processamento (ZHAO, 2020). Entre os protocolos mais usados é possível citar: os que trabalham com redes sem fio (Wireless, 4G, Lora, COAP, ZigBee, Sigfox, etc...), os que necessitam de uma rede com Fio (Modbus, CAN, i2c, etc..) e ainda os que trabalham diretamente por envio e recebimento de mensagem utilizando a internet como meio de comunicação (MQTT, XMPP, etc..). Esses protocolos são fundamentais para possibilitar o envio de informações entre a camada de percepção e a camada de processamento, descrita a seguir.

A Camada de Processamento permite que programadores trabalhem com os mais diversos hardwares que processam as informações recebidas através da camada de rede, tendo a capacidade de receber e tratar as informações de sensores e dispositivos (AL-FUQAHA et al., 2015).

Nesse contexto os dispositivos com tecnologia embarcada estão sendo cada vez mais utilizados, alguns desses dispositivos são desenvolvidos para atender demandas de prototipagem rápida e realização de testes de conceitos para estudos de viabilidade antes da produção real de algum equipamento ou sistema, o que reduz custos e as chances de possíveis erros em uma versão final.

Figura 7: Placa Arduíno e Raspberry Pi.



(a) Placa Arduíno

(b) Placa Raspberry Pi

Fonte: adaptados de (RICHARDSON; WALLACE, 2012)

Dois exemplos muito populares de plataformas de prototipagem rápida são o Arduíno e a Raspberry Pi, essas placas são muito úteis quando trata-se de prototipagem rápidas e processadores para dados de sensores e dispositivos (RICHARDSON; WALLACE, 2012).

A Camada de Aplicação é responsável por mostrar aos usuários as informações referentes aos sensores e dispositivos conectados a um processo, máquina ou equipamento, já a de negócios é responsável pela montagem de gráficos e fluxogramas com base no banco de dados que foi criado mediante as demais camadas anteriores (AL-FUQAHA et al., 2015). Os sistemas de supervisão são capazes de monitorar e controlar processos em tempo real, fornecendo uma grande quantidade de dados e informações que auxiliam na tomada de decisões, logo o gerenciamento dessa grande quantidade de dados em um curto período de tempo tornou-se impossível para pessoas.

A utilização de recursos computacionais para processamento e auxílio na tomada de decisões é corriqueiro dentro dos moldes da indústria 4.0, devido a grande quantidade de dados e informações. Dessa forma foram desenvolvidos vários algoritmos inteligentes, que trabalham não apenas para gerenciamento das informações, mas também na tomada de decisão e previsão de eventos. Esses algoritmos são conhecidos como Algoritmos de Aprendizado de Máquina e fazem parte de técnicas desenvolvidas dentro dos campos de aplicação da Inteligência Artificial.

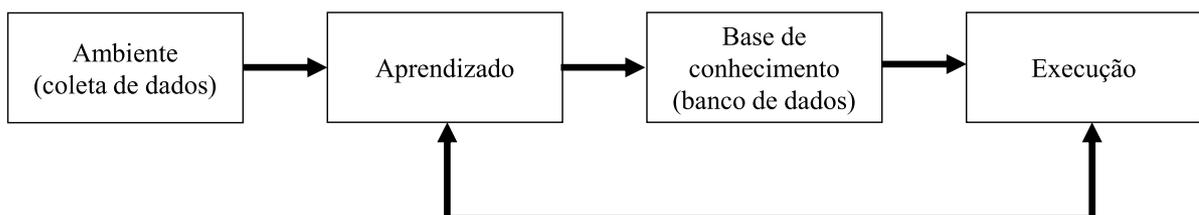
2.3 Inteligência Artificial

O conceito de Inteligência Artificial, ou somente AI, passou a ser estudado, desde a década de 40, quando da necessidade da construção de tecnologias para quebra de códigos e cálculos de armas nucleares. Na década de 50 Alan Turing pergunta em um de seus artigos: "As máquinas podem pensar?", desde então passou-se a discutir e desenvolver diferentes técnicas de inteligência artificial (TURING, 2009). O objetivo dessa área é desenvolver algoritmos que busquem simular e reforçar a capacidade de comportamentos inteligentes humanos, com base em padrões e bancos de dados existentes (NILSSON, 2014). Esses sistemas estão associados a características humanas como: compreensão, linguagem, aprendizado, raciocínio, entre outros (MELLIT; KALOGIROU, 2008). Com o aumento da capacidade computacional novas técnicas de AI são criadas e aperfeiçoadas constantemente. As áreas de aplicação de AI são as mais diversas, indo desde a solução de problemas matemáticos, até jogos, processamento de linguagem natural, automação e robótica (LIMA; PINHEIRO; SANTOS, 2016). Uma das áreas da AI é a de Aprendizado de Máquina do inglês - Machine Learning ou somente AM, que será detalhada nos próximos itens.

2.3.1 Aprendizado de Máquina

Aprendizado de Máquina, trata-se de uma área da AI aonde deseja-se construir sistemas computacionais que melhorem automaticamente conforme a experiência que é adquirida (JORDAN; MITCHELL, 2015). Isso significa que os sistemas aprendem automaticamente através de dados coletados (DOMINGOS, 2012). Em outras palavras, Aprendizado de Máquina trata-se de um programa de computador que otimiza suas funções de acordo com experiências passadas, as quais são armazenadas em um grande banco de dados (ALPAYDIN, 2020). O principal objetivo do uso de AM é obter novos conhecimento e experiências. Esses dados serão organizados permitindo uma melhora progressiva do sistema ou equipamento em questão (XUE; ZHU, 2009). É possível verificar a estrutura básica de um sistema de AM na Figura 8.

Figura 8: Estrutura básica sistema de Aprendizado de Máquina

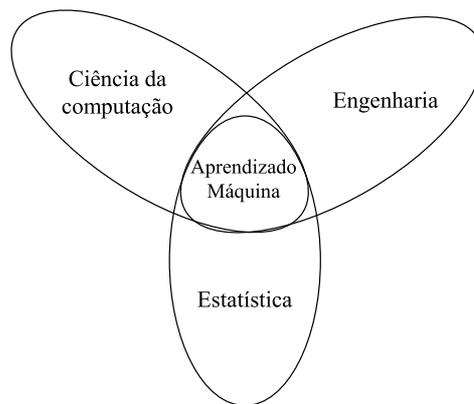


Fonte: adaptado de (XUE; ZHU, 2009)

A máquina ou processo coleta do ambiente dados, através da utilização de sensores e atuadores. Os dados são processados, fazendo com que o sistema aprenda quais os valores

mais adequados para as variáveis envolvidas na realização de uma determinada tarefa. Os dados armazenados geram aprendizado que também são armazenados. Em seguida todas essas informações são processadas, determinando qual ação deve ser realizada ou qual atualização é necessária para melhorar a atividade em questão. A ação é executada levando em consideração todos os dados e aprendizado de ciclos já passados (XUE; ZHU, 2009). Os algoritmos de AM são formados pela fusão entre ciência da computação, engenharia e estatística (DIVYA; BHARGAVI; JYOTHI, 2018), conforme demonstrado na Figura 9.

Figura 9: Fusão das área do conhecimento para Aprendizado de Máquina



Fonte: adaptado de (DIVYA; BHARGAVI; JYOTHI, 2018)

A interligação de sensores, atuadores, microprocessadores e placas, possibilitam a aquisição de dados. Lógicas de programação permitem a integração, funcionamento dos componentes físicos e aplicação de procedimentos estatísticos. Procedimentos estatísticos são usados para verificação da melhor metodologia de funcionamento adotar, definindo padrões com base no banco de dados do sistema ou equipamento (DIVYA; BHARGAVI; JYOTHI, 2018).

Os algoritmos de AM são divididos em dois grandes grupos:

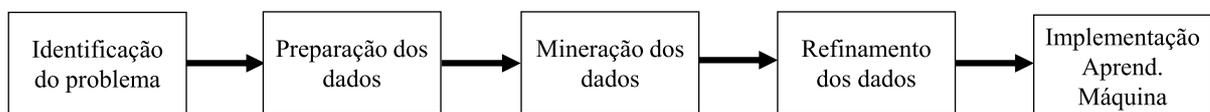
- **Aprendizado supervisionados:** nesse grupo os algoritmos de classificação e regressão são os mais comuns. O objetivo principal é encontrar similaridades ou estruturas tomando como base dados de entrada e saída já conhecidos, ou seja, o algoritmo é testado usando dados conhecidos, tanto para treinamento quanto para verificação da efetividade das respostas (SHANTHAMALLU et al., 2017);
- **Aprendizado não supervisionadas:** os algoritmos mais conhecidos desse grupo são os de clusterização, associação, redução de dimensionalidade, aprendizado de representações e estimativa de densidade. Nesse caso não será fornecidos rótulos de dados explicitamente e deseja-se aprender sobre a estrutura inerente dos dados. O objetivo principal é inferir utilizando os dados de entrada para então modelar a estrutura oculta e a distribuição dos dados, em outras palavras deseja-se encontrar subgrupos que tenham semelhanças (SHANTHAMALLU et al., 2017).

- **Aprendizado por reforço:** os algoritmos baseados em aprendizado por esforço, são os que necessitam de aprender a executar ações baseadas em experiência de acordo com cada ação executada, isso quer dizer que os algoritmos são forçados a aprender através do método de tentativa e erro. São muito utilizados no ramo da robótica, aonde deseja-se ensinar os robôs uma determinada ação (SUTTON; BARTO, 2011).

Em automação o uso de AM está associado a processos de engenharia do conhecimento, aonde substitui-se uma atividade humana demorada e/ou repetitiva por técnicas automáticas, melhorando a eficiência e precisão (LANGLEY; SIMON, 1995). O uso de automação, IoT e AI, permite o monitoramento remoto de dados e controle de variáveis de processo de forma precisa (KANAWADAY; SANE, 2017).

A fusão dessas tecnologias faz com que se obtenham sistemas ou máquinas autônomas, capazes de executar tarefas com base em reconhecimento estatístico de padrões, algoritmos paramétricos e não paramétricos, redes neurais, sistemas de recomendação, entre outros (VERMESAN et al., 2017). A definição do melhor algoritmo a ser implementado é feita com base nos dados que serão utilizados. Logo é necessário uma análise prévia sobre os dados. A Figura 10 demonstrará uma sequência adotada por (SOIBELMAN; KIM, 2002) e (ZHANG; ZHANG; YANG, 2003) para que seja implementado um algoritmo de AM.

Figura 10: Ciclo para análise dos dados



Fonte: adaptado de (ZHANG; ZHANG; YANG, 2003)

O primeiro passo para implementação de um algoritmo de AM é a identificação do problema o qual deseja-se utilizar AM. Em seguida é necessário fazer uma preparação dos dados, verificando quais as variáveis e parâmetros de interesse. Após isso é necessário a verificação de bancos de dados apropriados, que atendam a solução do problema e realizar uma “mineração” buscando pelo agrupamento de padrões mais adequados. Com os dados em mão é necessário realizar um refinamento dos mesmos, utilizando normalização, estimativa de erros e modelos. Por fim com uma análise detalhada sobre os dados é que se tem parâmetros para definição do melhor algoritmo de AM para solução do problema em questão (SOIBELMAN; KIM, 2002) (ZHANG; ZHANG; YANG, 2003).

Diante do exposto, pode-se perceber que para implementação de sistemas de AM é necessário, um banco de dados o qual servirá como base para aprendizado das máquinas e sistemas em que serão implementados. Esses dados podem ser independentes e distribuídos de forma idêntica ou temporais/sequenciais. Os dados temporais são adquiridos em relação ao tempo (horas, dias, semanas, meses) já os sequenciais atendem a uma ordem sequencial(MAHDAVINEJAD et al., 2018). Para que seja possível realizar a implementação

de um algoritmo de AM com um bom desempenho, é necessário realizar um refinamento nos dados disponíveis. Um bom tratamento prévio de dados, gera uma melhora significativa na acurácia dos algoritmos utilizados (ZHANG; ZHANG; YANG, 2003). É possível fazer uma análise dos dados de um sistema utilizando ferramentas estatísticas, essas ferramentas nos trazem informações importantes para escolha dos modelos de AM mais adequados para os dados em que se está trabalhando.

Os dados que serão trabalhados nessa dissertação tratam-se de dados temporais, os quais são adquiridos através da medição de CO_2 ao longo dos dias de testes da biodegradabilidade de materiais poliméricos. Diante disso serão exploradas algumas técnicas estatísticas para verificação do comportamento dos dados coletados. Através do comportamento dos dados serão definidas as melhores técnicas de AM para o modelo proposto.

2.3.2 Análises estatísticas

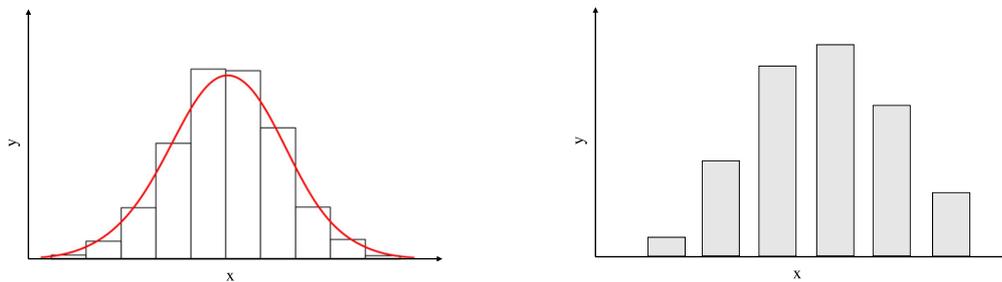
Conforme descrito no item anterior, é muito importante que seja feita uma análise dos dados os quais servirão como base para implementação dos algoritmos de AM. Na maioria das vezes esses bancos de dados são muito grandes, o que impossibilita uma análise visual direta. Logo, é necessário a aplicação de técnicas matemáticas e estatística para análise dos dados. Além de técnicas estatísticas para avaliação do comportamento dos dados, quando trabalhamos com IoT é necessário garantir que os sensores do sistema estejam medindo corretamente, dessa forma usa-se processos de calibração, os quais consistem em avaliar a correta medição dos sensores. Dessa forma serão agora exploradas algumas técnicas que servirão de apoio para análise dos dados e calibração aplicados a essa dissertação.

2.3.2.1 Distribuição estatística

Distribuições estatísticas ou distribuições de probabilidade são definidas por curvas gráficas ou histogramas, que determinam a probabilidade de ocorrência de um evento, com base nos dados desses gráficos. As distribuições de probabilidade são determinadas por histogramas ou gráficos ou tabelas de frequências. Para construção de distribuições de probabilidade é necessário agrupar os dados de uma série em grupos, chamados de frequência de dados. Essas distribuições podem ser classificadas como discretas ou contínuas. As distribuições discretas são aquelas cujo as variáveis aleatórias assumem cada um de seus valores com igual probabilidade. Já as distribuições contínuas são caracterizadas por uma função de densidade plana, logo a probabilidade é uniforme em um intervalo fechado. Em resumo as variáveis discretas podem assumir valores aleatórios contáveis em um intervalo determinado, podem ser representadas por tabelas, já as variáveis contínuas podem assumir infinitos valores em um intervalo conhecido, nesse caso é necessário que sejam representadas de forma gráfica (ÖZGÜN; BARLAS, 2009) (WALPOLE, 2009). Um exemplo de distribuição

de probabilidade contínua pode ser observada na Figura 11(a) e um exemplo de distribuição de probabilidade discreta pode ser observada na Figura 11(b):

Figura 11: Exemplos de distribuição de probabilidade



(a) Distribuição de probabilidade contínua (b) Distribuição de probabilidade discreta

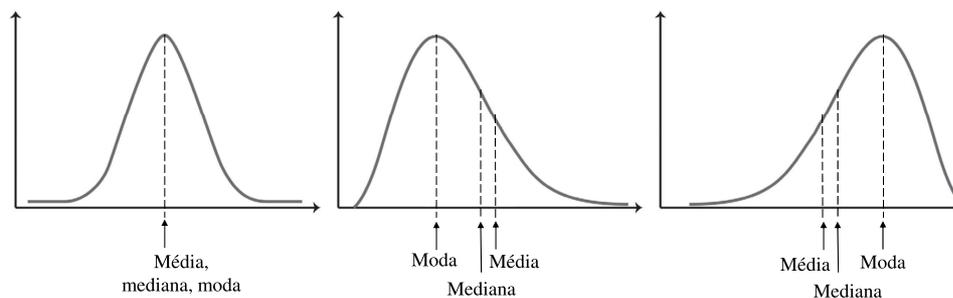
Fonte: adaptados de (WALPOLE, 2009)

Existem diversos tipos de distribuições, cada distribuição possui cálculos específicos da probabilidade de eventos serem verdadeiros ou falsos, média, mediana, variância desvio padrão, etc... Alguns exemplos de distribuições de probabilidade mais comuns são: Distribuição normal (demonstrado na Figura 11(a)) ou gaussiana, Distribuição t de Student, Distribuição exponencial, Distribuição Poisson e Distribuição binomial.

2.3.2.2 Média, mediana e moda

Muitas vezes cálculos matemáticos aplicadas a estatística clássica são importantes para verificação do comportamento de um conjunto de dados. O valor médio diz respeito ao número de ocorrências de valores um conjunto de dados. A mediana trata-se da posição média dos dados, dividindo os dados em duas partes. O valor de moda em um conjunto de dados baseia-se na totalidade dos dados que aparecem com mais frequência (JAIN, 1990). A Figura 12 mostra o posicionamento da média, moda e mediana em uma distribuição de dados, quando possui dados distorcidos ou perfeitamente distribuídos.

Figura 12: Comparação gráfica de média, mediana e moda

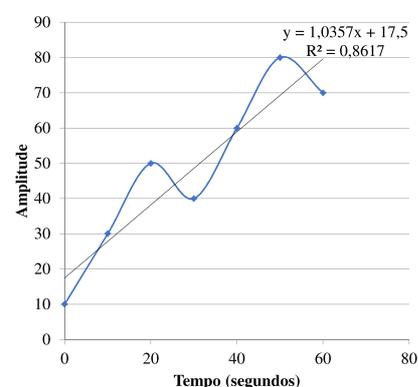
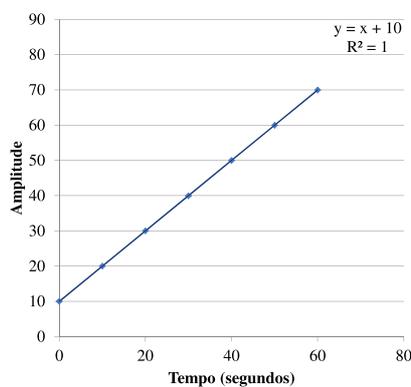


Fonte: adaptado de (JAIN, 1990)

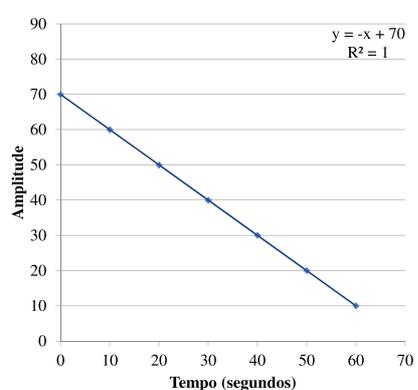
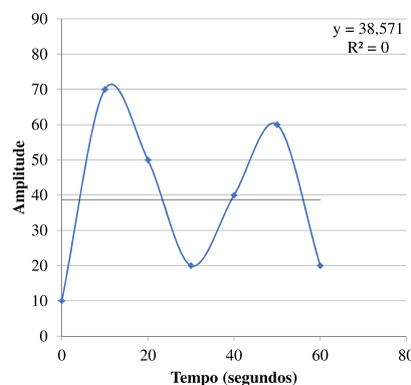
2.3.2.3 Correlação

A correlação trata-se de uma medida adimensional usada para comparar relações lineares entre pares de variáveis de diferentes unidades (MONTGOMERY; RUNGER, 2010). O coeficiente de determinação R^2 , é uma medida de ajuste de um modelo linear estatístico. Trata-se de um valor percentual que diz respeito a diferença entre os valores reais e o modelo determinado. Quanto mais próximo de 1 o valor de R^2 , mais preciso é a correlação entre os dados reais e um modelo (NAGELKERKE et al., 1991).

Figura 13: Exemplos de autocorrelação de dados



(a) Exemplo de série de dados com $R=1$ (b) Exemplo de série de dados com $R=0,8617$



(c) Exemplo de série de dados com $R=0$ (d) Exemplo de série de dados com $R=-1$

Fonte: elaborados pelo autor

As Figuras 13(a) 13(b) e 13 (c) 13(d), mostram a correlação entre diferentes conjuntos de valores. Onde percebe-se em 13(a): uma correlação positiva perfeita, 13(b) uma correlação de aproximadamente 86 % positiva, 13(c) nenhuma correlação entre os dados e 13(d) uma correlação perfeita de dados negativos (TAYLOR, 1990). Esses exemplos foram construídos tomando como base dados temporais distribuídos ao longo do tempo.

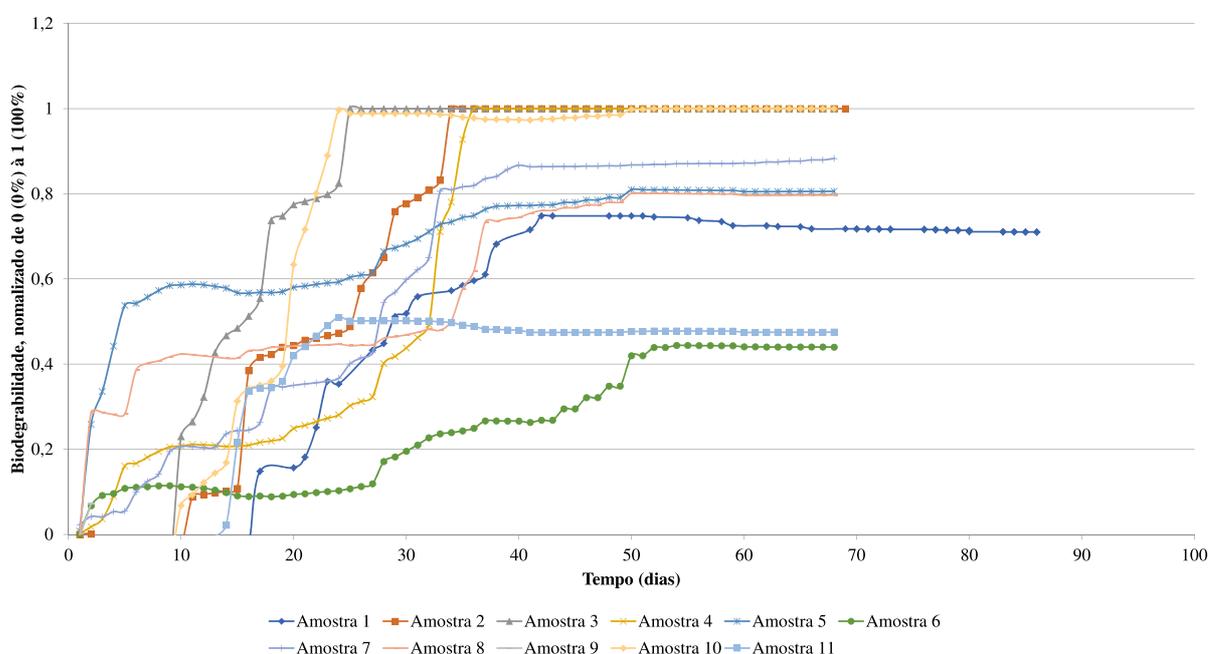
Os dados coletados de um determinado sistema pode ser classificado de acordo com seus comportamentos e aquisição. Uma forma de organização e aquisição de dados, pode ser dada com períodos fixos ao longo do tempo. Esse tipo de dados é chamado de Série Temporal, as

quais serão exploradas no próximo capítulo.

2.3.2.4 Séries temporais

Séries temporais tratam-se de sequências numéricas ordenadas em ordem cronológica através de intervalos de tempo. Para realização de análises de séries temporais, é necessário a verificação da estrutura padrão dos dados a serem analisados o que irá permitir a adaptação de um modelo que possibilitará a utilização de técnicas de AM para realizar previsões futuras (BROCKWELL; DAVIS, 2016) (RAMSAY; SILVERMAN, 2007).

Figura 14: Gráfico de exemplo de séries temporais de ensaios do percentual de biodegradabilidade de materiais poliméricos



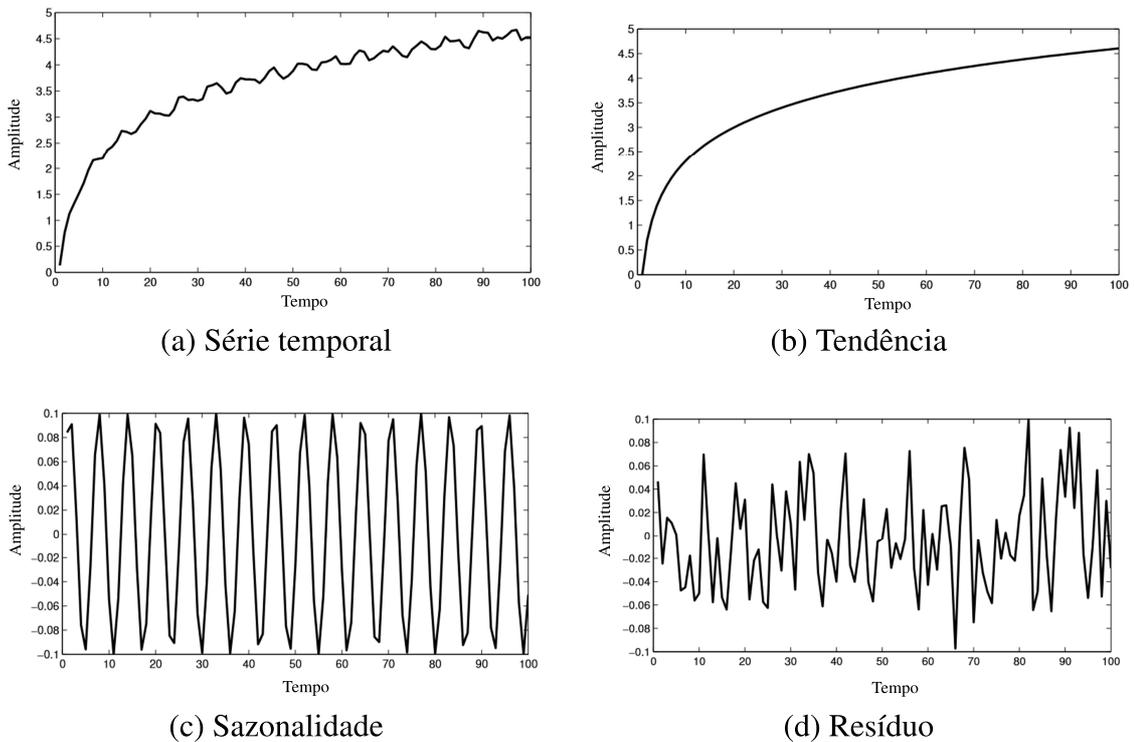
Fonte: elaborado pelo autor

As séries temporais são representadas graficamente. Na Figura 14 temos um exemplo de gráfico que demonstra a emissão de CO_2 de ensaios de biodegradabilidade de materiais poliméricos, aonde no eixo x temos o tempo em dias e no eixo y os valores acumulados de CO_2 medidos. A análise de séries temporais é utilizada para muitas aplicações, incluindo previsões, controle de processo, qualidade, etc. Uma série temporal pode ser dividida em três componentes (MARTÍNEZ-ÁLVAREZ et al., 2015) (AHMAD et al., 2014).

- Tendência: movimentação geral da variável em análise, sem considerar sazonalidade e irregularidade;
- Sazonalidade: trata-se da flutuação periódica da variável em análise, são efeitos estáveis, juntamente com o tempo, magnitude e direção;

- Resíduos: parte restante da série temporal, muitas vezes inexplicável e podem mascarar a tendência e a sazonalidade.

Figura 15: Componentes gráficos de uma série temporal



Fonte: adaptados de (MARTÍNEZ-ÁLVAREZ et al., 2015)

A Figura 15(a) mostra um exemplo de gráfico de série temporal qualquer, a Figura 15(b) demonstra os dados de tendência de uma série temporal, a Figura 15(c) a sazonalidade e a Figura 15(d) o resíduo. O refinamento dos dados de interesse pode ser complexo e depende da utilização de vários cálculos matemáticos. Porém esse filtro de informações é indispensável para que se tenha um modelo de AM com uma boa acurácia, ou seja, baixo erro nas previsões.

Sabendo que os dados os quais serão trabalhados nessa dissertação, são classificados como séries temporais, realizou-se uma busca na literatura, com o objetivo de verificar quais os algoritmos de Aprendizado de Máquina mais utilizados para implementação de sistemas de previsão em séries temporais. Os algoritmos pesquisados serão enunciados no próximo capítulo.

2.3.3 Técnicas de Aprendizado de Máquina

Conforme visto anteriormente, verifica-se que as técnicas de AM se vale de teorias estatísticas e cálculos matemáticos que fazem com que o sistema ou máquina tenha a capacidade de aprender tomando como referência experiências passadas. Existem técnicas de

AM que podem ser aplicadas de acordo com o comportamento dos dados armazenados, o que justifica o review de algumas análises estatísticas no item anterior. Diante do exposto até então, serão exploradas agora algumas técnicas de Aprendizado de Máquina, justificando a utilização de cada uma para determinados comportamentos dos dados analisados, iniciando por técnicas estatísticas de regressão e ARIMA, seguidas por técnicas de AM utilizadas para predição de resultados.

2.3.3.1 Regressão

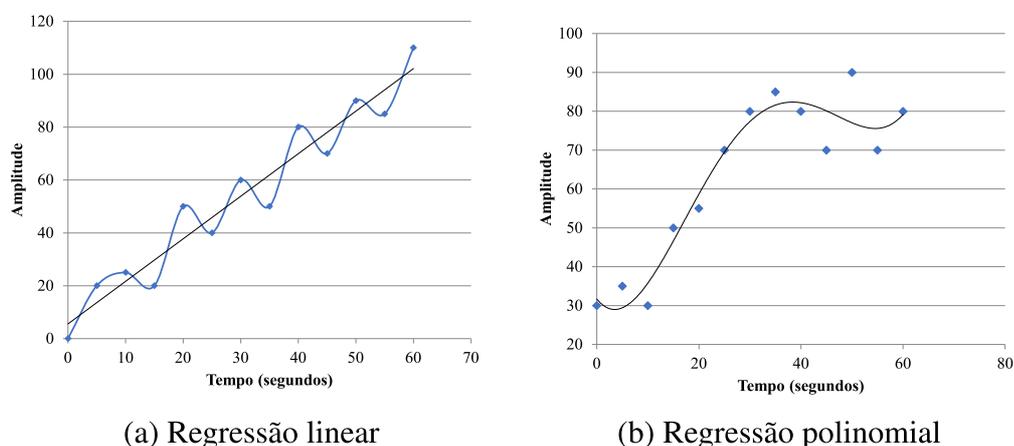
Regressão linear trata-se de um dos modelos mais simples de regressão utilizados para predição de resultados (ACHARYA; ARMAAN; ANTONY, 2019). É uma técnica de estimação entre valores de entrada e saída de um sistema (SHANTHAMALLU et al., 2017). Os modelos de regressão linear podem possuir uma ou mais variáveis. Nesse tipo de técnica existe uma equação que descreve uma linha reta aos pontos de dados, a qual é ajustada para descrever o comportamento entre as variáveis de entrada x e as variáveis de saída y (DIVYA; BHARGAVI; JYOTHI, 2018). Um exemplo de sistema de regressão linear com a equação linear correspondente e as respostas do sistema é mostrado na Figura 16(a).

O relacionamento entre a função de hipótese e os dados de uma regressão linear é expresso pela equação 2.1:

$$h(x) = w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n \quad (2.1)$$

Aonde x são os valores de entrada e w os pesos do modelo. Os modelos de regressão linear são melhores escritos quando se trabalha com séries estacionárias, ou seja, quando os valores da série estão em torno de uma mesma média ao longo do tempo. Os modelos de regressão linear, escrevem uma reta sobre os dados de amostragem.

Figura 16: Exemplo de regressão linear e polinomial



Fonte: elaborados pelo autor

Com conceitos similares a regressão linear, existe a regressão polinomial, que escrevem um polinômio sobre os dados de amostragem, conforme demonstrado na Figura 16(b). Outra análise estatística muito utilizada em Aprendizado de Máquina é a de ARIMA, descrita no próximo item.

2.3.3.2 ARIMA

ARIMA significa Autoregressive Integrated Moving Average (Média Móvel Integrada Autorregressiva), ou seja, trata-se de um modelo de média móvel autorregressivo. Os modelos de ARIMA podem conter uma parte autorregressiva (AR), média pura (MA) ou ambas combinadas (ARMA) (ZHANG, 2003). A equação de ARIMA consiste na previsão de valores futuros de uma variável assumindo este como uma função linear de várias observações passadas e erros aleatórios (DEB et al., 2017). As previsões do modelo de ARIMA pode ser dados pela equação 2.2:

$$y_i = \theta_0 + \varphi_1 y_{i-1} + \varphi_2 y_{i-2} + \dots + \varphi_p y_{i-p} + \xi_i - \varphi_1 \xi_{t-1} - \theta_2 \xi_{t-2} - \dots - \theta_q \xi_{t-q} \quad (2.2)$$

Onde y_t e ξ_t são reais e t o erro aleatório. φ_i ($i = 1, 2, \dots, p$) e θ_j ($j = 1, 2, \dots, q$) são parâmetros de modelo. p e q são números inteiros, denominados como ordem do modelo. ξ_t , são erros aleatórios assumidos independentemente e identicamente distribuídos com uma média de zero e uma variância de σ^2 .

Os modelos de ARIMA não são eficazes quando se trabalha com padrões não lineares, sendo necessário uma linearização antes da aplicação desses modelos, porém nem sempre a aproximação por modelos lineares é adequada para situações do mundo real. Para utilização dos modelos de ARIMA é necessário que a série de dados seja estacionária, caso contrário é necessários aplicar técnicas de estabilização, para eliminar as variações indesejadas (ZHANG, 2003).

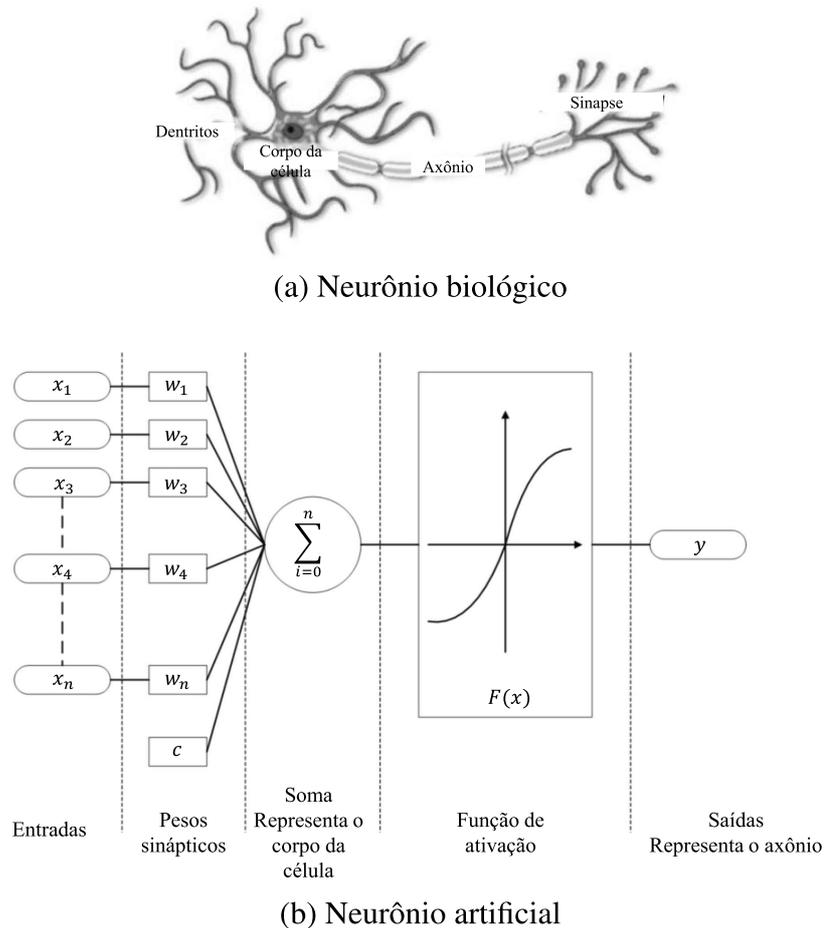
2.3.3.3 Redes Neurais Artificiais

As redes neurais artificiais – RNN são técnicas de modelagem, que se enquadram dentro dos conceitos de Deep Learning. Os algoritmos baseados em RNN são modelados através de funções matemáticas e buscam um funcionamento similar ao cérebro humano (DEB et al., 2017).

Um neurônio biológico é demonstrado na Figura 17(a). O mesmo é constituído por quatro partes principais: dendritos, axônios, corpo da célula e terminais sinápticos. Os dendritos captam os impulsos com as informações e são responsáveis por repassar as mesmas para o corpo da célula. O axônio recebe os sinais a partir do corpo da célula e os transporta para os dendritos que vão enviar informações aos neurônios vizinhos através da sinapse (BUDUMA;

LOCASCIO, 2017). Comparando as redes artificiais e as biológicas, nas Figuras 17(a) e 17(b) é possível perceber a similaridade entre um neurônio artificial e um biológico.

Figura 17: Neurônios biológico e artificial



Fonte: adaptados de (BUDUMA; LOCASCIO, 2017)

A Figura 17(b) demonstra a proposta de McCulloch e Pitts em 1943 (MCCULLOCH; PITTS, 1943) sobre a implementação de redes neurais artificiais. As redes com apenas um neurônio são chamadas de perceptron. Sinais binários representam as entradas da rede (x). Cada sinal é multiplicado por um número denominado de peso (w), esse peso representava a influência na saída da rede (y). A variável (c) serve para aumentar o grau de liberdade da rede. Após a multiplicação pelos pesos é então feita a soma ponderada dos sinais e aplicado uma função de ativação $F(x)$. Em seguida caso um certo nível fosse atingido era produzida uma resposta determinada na saída (GÉRON, 2019). O principal objetivo das RNA é identificar quais os pesos mais adequados através do treinamento do modelo com dados passados (DEB et al., 2017).

Problemas mais complexos, geralmente, tratam-se de problemas não lineares, dessa forma é necessário a aplicação de uma função de ativação. Essas funções de ativação introduzem não linearidades ao neurônio da rede (GOODFELLOW; BENGIO; COURVILLE, 2016). Algumas

funções de ativação $F(x)$ são descritas por (SARLE, 1994) e (LIEW; KHALIL-HANI; BAKHTERI, 2016):

- Função linear ou identidade: os valores da saída são os próprios valores da entrada, conforme Figura 18(a) e equação 2.3:

$$F(x) = x \quad (2.3)$$

- Função degrau ou limite: a saída é igual a 1 caso o valor obtido pela soma ponderada das entradas seja maior ou igual a zero, caso contrário será -1, conforme Figura 18(b) e equação 2.4:

$$F(x) = \begin{cases} 1 & \text{se } x \geq 0 \\ 0 & \text{se } x < 0 \end{cases} \quad (2.4)$$

- Sigmoides: a função sigmoide possui graficamente um formato de "S". Nessa função quando a soma ponderada das entradas for pequena a saída será aproximadamente 0. Quando a soma ponderada for grande, a saída será aproximadamente 1, conforme Figura 18(c) e equação 2.3.3.3:

$$F(x) = \frac{1}{1 + e^x} \quad (2.5)$$

- Tangente hiperbólica: Similar a função sigmoide. Porém com intervalo de variação é de -1 a 1, conforme Figura 18(d) e equação 2.6:

$$F(x) = \tanh(x) \quad (2.6)$$

- Gaussiana: função característica por uma distribuição normal, conforme Figura 18(e) e equação 2.7:

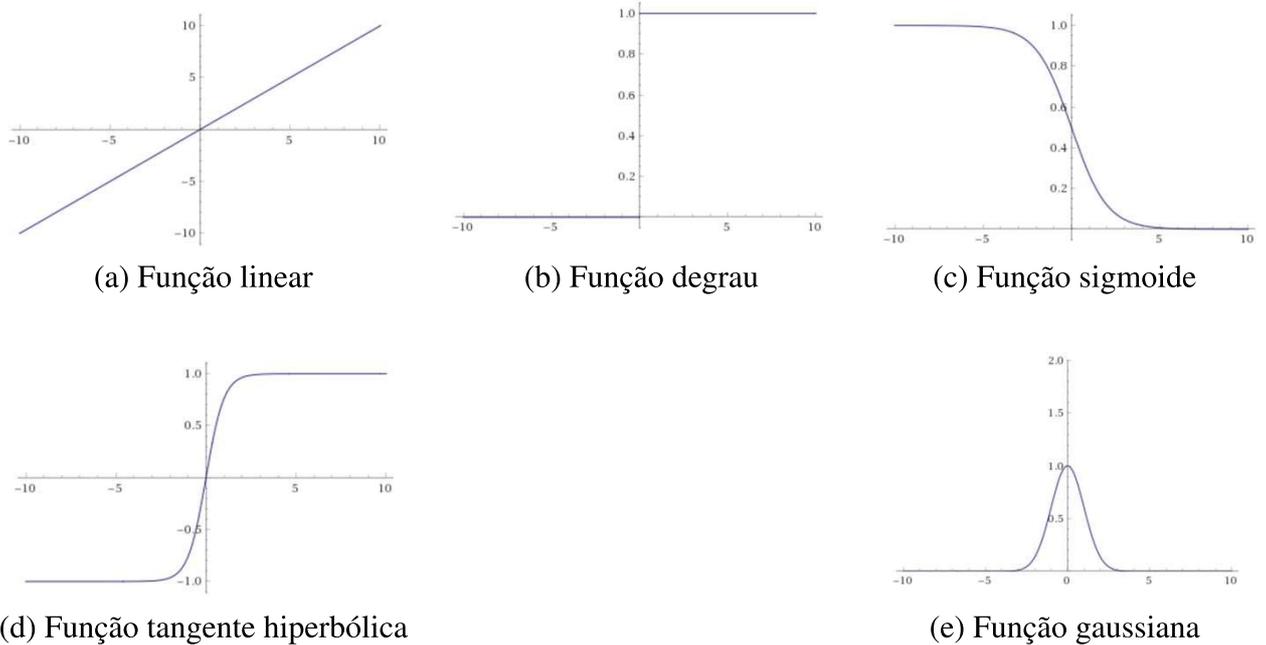
$$F(x) = e^{-\frac{x^2}{2}} \quad (2.7)$$

Existem muito tipos de arquiteturas de Redes Neurais Artificiais, as mais simples são: as Redes Neurais Multicamadas - MLP, as Redes Neurais Convolucionais - RNC e Redes Neurais Recorrentes - RNR. A seguir será feita uma descrição breve sobre essas arquiteturas ditas como básicas de Redes Neurais Artificiais (LECUN; BENGIO; HINTON, 2015).

2.3.3.4 Redes Neurais Multicamadas - MLP

O modelo introduzido por McCulloch (1943) trata-se de um modelo de perceptron simples (MCCULLOCH; PITTS, 1943), sendo esse o modelo mais simples de uma RNA, aonde é calculado uma combinação linear das entradas (SARLE, 1994). Bishop em 1995 iniciou os trabalhos com RNA de perceptrons de multicamadas (BISHOP et al., 1995). Nesses modelos existem camadas ocultas de neurônios, mesmo com uma única camada de pesos a ser estimada

Figura 18: Exemplos de funções de entrada



Fonte: elaborados pelo autor e gerados através do software (Wolfram Alpha - Computational Intelligence, 2020)

(SARLE, 1994). Cada sinal de saída de um neurônio é repassada para as camadas subjacentes, logo o sinal de saída é dado pelo processamento de todos os sinais de saída da camada anterior. Uma rede neural de perceptron multicamadas pode ser expressa pela equação 2.8:

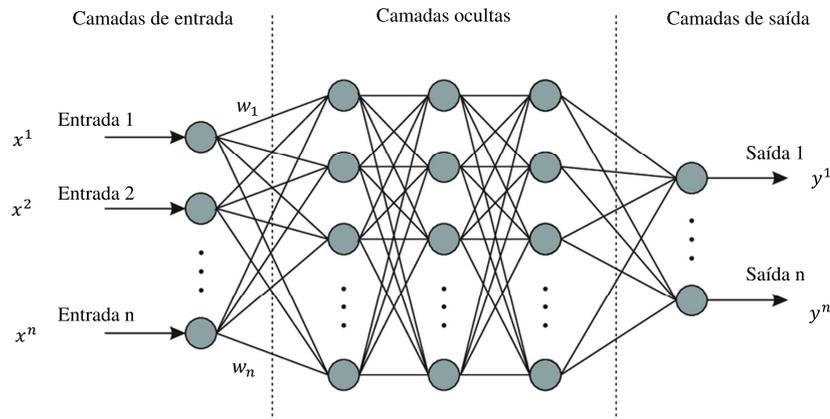
$$y^i = F\left(\sum_{i=0}^n w^i x^{i-1} + b^i\right) \quad (2.8)$$

Onde y é a saída da camada i e w são os pesos da camada x , $i - 1$ as saídas da camada anterior, b é o bias da camada atual e F a função de ativação. (HAYKIN, 2010)

A Figura 19 demonstra a representação de uma rede neural perceptron multicamadas:

Nesse tipo de rede as informações transitam de forma unidirecional entre camadas ocultas da rede, tendo como sentido de direção dos dados da entrada para a saída. A rede faz o ajuste de seus pesos com base na quantidade de épocas (repetições de passagem por toda a rede) que é determinada, porém a informação passa apenas um vez por cada neurônio, quando chega ao final da rede, é feita uma nova passagem e reajustado os pesos, com o objetivo de chegar a um menor erro entre dados de treinamento e teste da rede. Devido a passagem univoca da informação pelos neurônios essas redes não possuem a capacidade de armazenar uma memória sobre os dados de entrada. Sendo assim na década de 90 as redes neurais foram aperfeiçoadas e foram então desenvolvidas as Redes Neurais Recorrentes (MEDSKER; JAIN, 2001).

Figura 19: Perceptron multicamadas

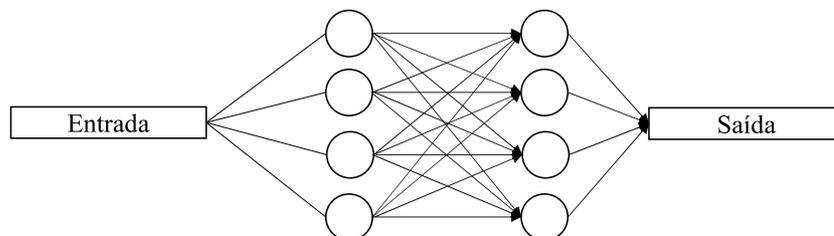


Fonte: adaptado de (GOODFELLOW; BENGIO; COURVILLE, 2016)

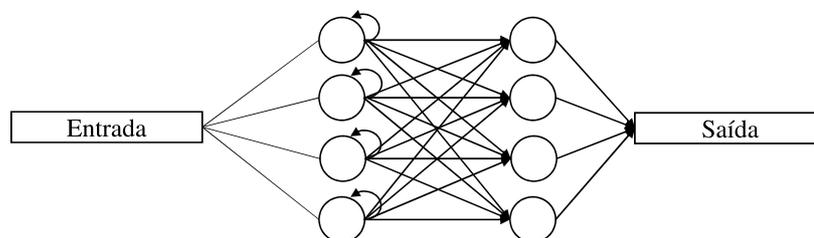
2.3.3.5 Redes Neurais Recorrentes

As redes recorrentes tratam-se de um tipo de Rede Neural Artificial projetada para reconhecer padrões em seqüências de dados, como: séries temporais, textos, sequencias numéricas, etc. As RNR possuem realimentação entre seus neurônios, formando um loop que funciona como uma memória para a rede (OLAH, 2015).

Figura 20: Comparação entre rede neural multicamadas e recorrente



(a) Rede Neural Multicamadas



(b) Rede Neural Recorrente

Fonte: adaptado de (OLAH, 2015)

A realimentação da rede faz com que os valores de saída tenham influência do passado $t - 1$ (atraso temporal unitário). Os valores possuem defasagens temporais resultando em comportamento dinâmicos não-lineares. Isso faz com que a rede tenha uma espécie de

memória, pois a informação anterior passa novamente para seus neurônios. A equação 2.9 descreve o comportamento da memória da Rede Neural Recorrente:

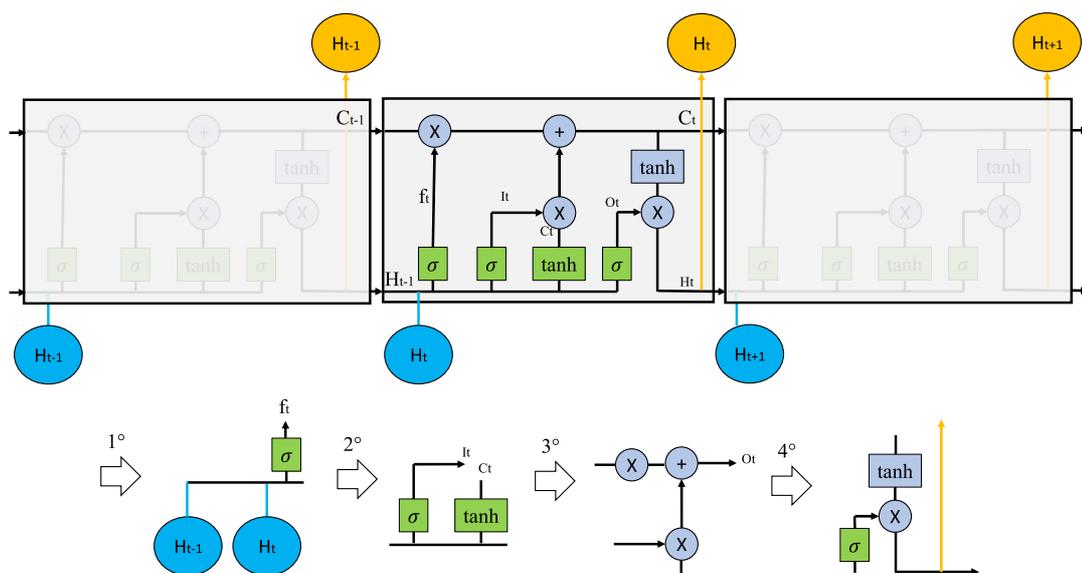
$$h_t = \phi(Wx_t + Uh_{t-1}) \quad (2.9)$$

Onde estado oculto na etapa de tempo é h_t . A função da entrada na mesma etapa de tempo x_t , modificada por uma matriz de peso W adicionada ao estado oculto do passo de tempo anterior h_{t-1} multiplicado por seu próprio estado oculto U .

Conforme descrito as RNR são capazes de "aprender" e utilizar informações do passado para previsão de informações futuras. Porém, essas Redes são incapazes de utilizar uma longa memória em suas aplicações, além de que a multiplicação excessiva entre as camadas ocultas pode fazer com que as ativações de diferentes estados sejam embutido no ruído multiplicativo. Sendo assim, foi então introduzido ao universo das Redes Neuras Recorrentes as LSTM - Long Short-Term Memory, do inglês Memória de Curto e Longo Prazo. As LSTM são poderosas em memórias de longo prazo (AGGARWAL et al., 2018). Essas redes tem a capacidade de manter um controle refinado sobre dados de uma memória de longo prazo (MEDSKER; JAIN, 2001).

As RNR comuns trabalham com estruturas interagindo em forma de cadeia simples, enquanto as LSTM possuem quatro. As LSTM podem remover ou adicionar informações ao estado da célula, o controle desses dados são realizados através de portões: Forget gate: faz a liberação/apaga, da memória da rede, Input Gate: adiciona na memória da rede e o Output gate: faz a leitura da memória da rede, jogando a informação para o próximo neurônio da rede (OLAH, 2015). A Figura 21 faz a ilustração do funcionamento de uma LSTM:

Figura 21: Esquema de funcionamento de uma Rede Neural Recorrente LSTM



Fonte: adaptado de (GOODFELLOW; BENGIO; COURVILLE, 2016)

As equações que formam uma LSTM são apresentadas a seguir:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_i) \quad (2.10)$$

$$I_t = \sigma(W_i[h_{t-1}, x_t] + b_f) \quad (2.11)$$

$$C_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (2.12)$$

$$C_t = f_t[C_{t-1} + i_t C_t] \quad (2.13)$$

$$O_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (2.14)$$

$$h_t = O_t \tanh(C_t) \quad (2.15)$$

A linha superior aonde existem os operadores X e $+$, trata-se da linha onde é adicionado ($+$) ou retirado (X) as informações da rede. No primeiro passo o dado anterior e o dado atual entram na rede (h_{t-1} e h_t) passam por uma função sigmoide (σ) a qual retorna "1" para manter o dado e "0" para apaga-lo, essa decisão é tomada de acordo com a importância do dado. Na sequência a rede irá decidir o que será armazenado pela rede através de uma função sigmoide (σ) e uma tangente hiperbólica (\tanh). Essas informações atualizam os estados através do Forget Gate (X) e do Input Gate ($+$). E, por fim é verificado qual será a saída em (σ) e (\tanh). Toda essa transição é feita em um único neurônio da rede e por isso as LSTM são tão robustas.

2.4 Desintegração Acelerada de Materiais Poliméricos – Biodegradabilidade

Conforme visto nos itens anteriores na quarta revolução industrial a preocupação passou a ser não apenas com a produção, mas sim o controle do produto como um todo, desde o sua fabricação de forma ágil, automatizada e limpa, tempo de vida útil, até o seu descarte. O que resultou na busca por outros tipos de materiais menos agressivos ao meio ambiente e de fácil manipulação.

Uma das áreas que tem crescido muito é a de materiais Poliméricos. Segundo a (Abiplast - Associação Brasileira da Indústria do Plástico, 2019), desde o surgimento dos Polímeros até os dias atuais os plásticos trouxeram um grande avanço na tecnologia e em suas aplicações, que vão desde embalagens plásticas até equipamentos médicos e aviação. De acordo com (Plastics Europe - Association of Plastics Manufactures, 2019), em 2018, foram produzidos mais de 348 milhões de toneladas de materiais plásticos. Com o aumento da produção de materiais poliméricos, surgiram também preocupações quanto ao descarte ou aproveitamento dos mesmos e isso tem feito com que as empresas e organizações passem a procurar por novas alternativas para reduzir os riscos ambientais (SILVEIRA et al., 2019).

Cinelli et al. (2019) descreve que a eliminação de resíduos poliméricos é desafiadora, pois os métodos de incineração, necessitam de um controle de combustão avançado pois os resíduos emitidos podem poluir o ar, reciclagem química e mecânica requerem sistemas avançados de coleta (CINELLI et al., 2019). Diante disso os estudos sobre materiais com maior facilidade de decomposição tiveram um aumento e muito tem se falado em compostos Biodegradáveis.

Segundo ASTM D883-20 polímeros biodegradáveis são aqueles que degradam de forma natural, através da presença de microrganismos como bactérias e fungos. Porém para que um material seja declarado como biodegradável é necessário a realização de alguns ensaios (D883-20, 2019). Assim, Foram criadas algumas normas que podem ser utilizadas, essas normas atestam a biodegradabilidade dos materiais utilizando escalas laboratoriais, simulando ambientes marinhos e solos, com processos aeróbicos e anaeróbicos. Os processos aeróbicos são classificados pela circulação forçada de ar na amostra e composto de teste, já os anaeróbicos não possuem a circulação de ar. Em geral os métodos aeróbicos são aplicados para testes que utilizam solo, enquanto os anaeróbicos para processos em ambientes marinhos. (RUGGERO; GORI; LUBELLO, 2019).

Os ensaios de biodegradabilidade determinam o percentual de biodegradabilidade do material em teste. Esse percentual é calculado com base na emissão de Dióxido de Carbono (CO_2) que é liberado pelo ataque dos micro organismos na amostra em teste. A emissão de CO_2 é dividida em quatro fases:

1 - Fase de atraso: inicialmente existem pouco micro organismos, logo a emissão de CO_2 é baixa;

2 - Fase de degradação: com o passar do tempo os micro organismos se multiplicam, iniciando a decomposição do material polimérico;

3 - Fase de estabilização: após a decomposição do material polimérico, existe a redução dos micro organismos e conseqüentemente baixa emissão de CO_2 ;

4 - Medição da biodegradabilidade: nesse momento não existem mais emissão significativa de CO_2 , devido à falta de material e micro organismos, logo o teste está concluído.

O percentual de biodegradabilidade é definido com base em alguns cálculos. Inicialmente é definido o valor teórico de emissão de CO_2 , através das equações 2.16 e 2.17:

$$ThCO_2 = M C \frac{44}{12} \quad (2.16)$$

No qual:

M: massa do material testado (g)

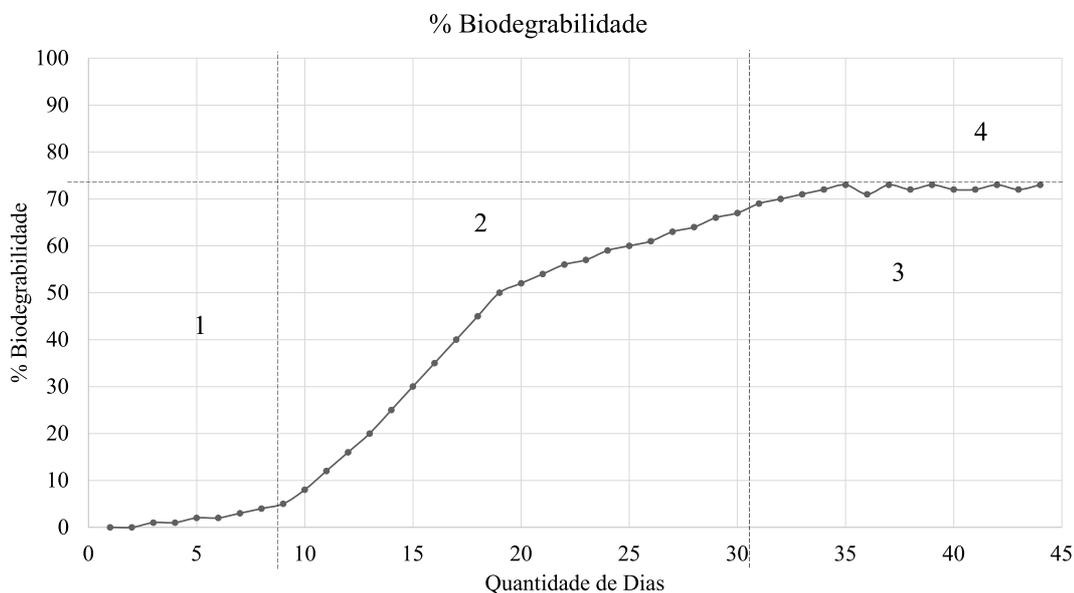
C: determinação do teor orgânico total da amostra de teste TOC (%UR)

44/12: massa molar do CO_2

$$D = \frac{TCO_2 - BCO_2}{ThCO_2} \quad (2.17)$$

No qual:

Figura 22: Representação das fases de biodegradabilidade



Fonte: elaborado pelo autor

$T\text{CO}_2$: valor de CO_2 medido no reator de teste com amostra e solo

$B\text{CO}_2$: valor de CO_2 medido somente no solo (branco)

$Th\text{CO}_2$: valor teórico estimado de CO_2

Além dos controles de emissão de CO_2 outras variáveis devem ser selecionadas, garantindo assim uma padronização, tornando os ambientes de simulação confiáveis e o ensaio reprodutivo. O valor de cada variável vai depender do tipo de teste e ambiente de simulação. Esses valores são definidos conforme normas e devem ser seguido à risca para realização dos testes. Entre as normas para determinação de biodegradabilidade, podemos citar oito mais utilizadas: ISO 20200, ISO 16929, ISO 14855, EN ISO 14851, EN 14806, EN 14045, EN 13432 e ASTM D5988. Ambas as normas tem suas peculiaridades e ambientes de aplicação, fornecendo ao final dos testes o percentual de biodegradabilidade do material. Essa dissertação é focada nos testes realizados em solo, tendo como base as normas ISO 14855, ASTM D5988 e ABNT NBR 15448-2, porém é importante salientar que a correta validação de um modelo, permitirá a construção de um protótipo para uma determinada norma, abrindo caminhos para o desenvolvimento de novos equipamentos que utilizem outras normas como referência.

2.4.1 Normatização

Normas tratam-se de documentos escritos para que seja seguido um determinado padrão para realização de uma tarefa e/ou produção de um produto, com o intuito de garantir a sua correta e melhor forma de execução, garantindo assim um padrão unívoco independente da pessoa que o fizer. A determinação do percentual de biodegradabilidade é feito com base em normas específicas para esses ensaios/testes. Com isso, nos próximos itens serão descritos as metodologias utilizadas para realização dos ensaios de biodegradabilidade em ambientes terrestres (solo).

2.4.1.1 ASTM D5988

A ASTM – American Society for Testing and Materials, é um órgão sem fins lucrativos que trabalha na publicação de normas técnicas. A norma ASTM D5988 - Test Method for Determining Aerobic Biodegradation of Plastic Materials in Soil, trata-se de uma norma para realização de testes para verificar o percentual de biodegradabilidade de materiais poliméricos em condições controladas.

A norma utiliza ambiente terrestre como meio de teste (solo) e é tratada como um processo aeróbico, o percentual de biodegradabilidade é definido através da emissão de CO_2 durante o período de teste que pode variar de 90 à 180 dias. Os reatores devem possuir volume de 2 a 4 litros, a temperatura de teste deve ser de 20 °C ou 28 °C com variações máximas permitidas de 2 °C e a umidade deve ser mantida entre 50 %UR e 70 %UR.

2.4.1.2 ABNT NBR 15448-2

ABNT - Associação Brasileira de Normas Técnicas, também trata-se de uma entidade privada sem fins lucrativos, que é responsável pela elaboração das normas brasileiras (ABNT NBR), sendo também avaliadores da conformidade e certificações de produtos. A norma ABNT NBR 15448-2 - Embalagens plásticas degradáveis e/ou de fontes renováveis Parte 2: Biodegradação e compostagem - Requisitos e métodos de ensaio, é a norma brasileira para realização de teste de biodegradabilidade.

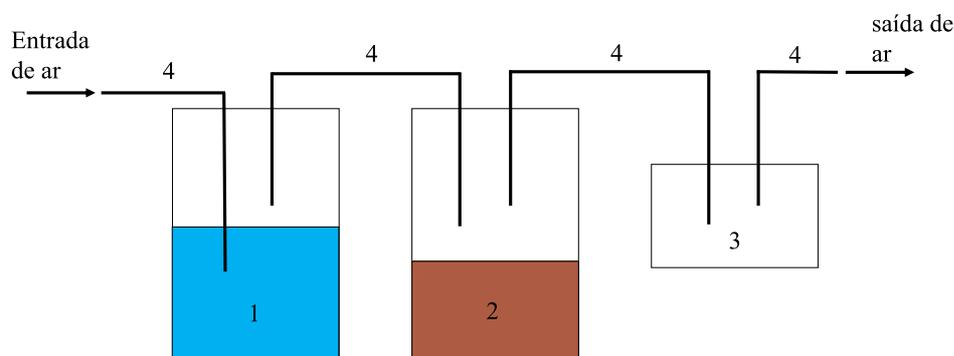
A norma utiliza ambiente terrestre como meio de teste (solo) e é tratada como um processo aeróbico, o método de definição da biodegradabilidade e o tempo de exposição são iguais a norma ASTM D5988 acima citada. Para as demais condições de ensaio, a norma ASTM D5988 faz referência a norma ISO 14855.

2.4.1.3 ISO 14855

A ISO - International Organization for Standardization, possui a norma ISO 14855-1 - Determination of the ultimate Aerobic Biodegradability of Plastic Materials under Controlled Composting Condition – Method by Analysis of Enveloped Carbon Dioxide – Part 1: General Method, na grande parte dos casos essa norma é citada pelas demais como referência para os testes de biodegradabilidade de materiais poliméricos. A duração e ambiente de teste são iguais as demais normas acima citadas, a temperatura de teste agora é de 58 °C com variações máximas permitidas de 2 °C. Os reatores de teste devem ser de 2 litros e a umidade de teste deve ser mantida em torno de 50 %UR, sem definição fixa de variações aceitáveis. Os testes são validados se três condições são atendidas:

- 1 – o material de referência (celulose ou amido) devem degradar 70 %UR depois de 45 dias;
- 2 – o ensaio deve ser feito em triplicata e a diferença entre os reatores de teste deve ser menor que 20 %UR;
- 3 – o composto utilizado como branco (reatores apenas com solo) devem produzir valores de CO_2 entre 50 mg e 150 mg em 10 dias de teste.

Figura 23: Representação de testes de biodegradabilidade pela norma ISO 14855



Fonte: adaptado de (ISO; STANDARD, 2012)

O sistema proposto pela norma ISO 14855 é ilustrado na Figura 23, cada teste deve possuir pelo menos três reatores com composto (solo) que irão servir como branco, para verificação da emissão de CO_2 sem amostra de teste, mais três reatores com o material de referência para verificação da correta montagem do sistema e outros três reatores com composto e material de teste.

Conforme observado na Figura 23 o ar forçado é circulado em todo o sistema através de uma tubulação inerte (4), o qual passa por uma solução de $NaOH$ (1) para remoção do CO_2 do ar. O segundo reator possui o composto de teste (2) e o ar é direcionado para a medição de CO_2 (3). Diante da análise dessas normas foram buscados na literatura por pesquisas que implementaram um sistema automatizado para realização dos testes de biodegradabilidade de materiais poliméricos e serão apresentados alguns desses desenvolvimentos na próxima capítulo.

3 TRABALHOS RELACIONADOS

Nesse capítulo serão apresentados trabalhos desenvolvidos por outros pesquisadores, tomando como base artigos internacionais já publicados. É possível perceber uma lacuna entre as publicações que envolvem ensaios de biodegradabilidade entre os anos de 2006 e 2015, acredita-se que isso se dá ao fato da baixa preocupação com o descarte desse tipo de materiais nesse período, visto que no ano de 2015 após a publicação de várias notícias, referente a canudos plásticos em ambientes marinhos, as pesquisas por materiais biodegradáveis retornou.

3.1 Metodologia de pesquisa e seleção de trabalhos

O processo de seleção de trabalhos relacionados foi feito tomando como base quatro etapas: a) pesquisas através de termos relacionados ao estudo do trabalho proposto; b) leitura do título e resumo; c) leitura da introdução e conclusão; d) leitura completa do artigo.

Inicialmente realizou-se algumas buscas utilizando palavras isoladas e foi então que percebeu-se que existiam poucos artigos publicados sobre o assunto. Foram feitas buscas tomando como base palavras chaves, assim foi elaborada a primeira String de busca, que será definida a seguir, porém eram inclusas palavras como ("IoT"), ("Machine Learning"), ("Predição"), essa busca não resultou em nenhum trabalho tomando como base os seguintes questionamentos:

1) Trata-se de um trabalho que leva em consideração a avaliação da biodegradabilidade de materiais?

2) É realizado algum tipo de implementação de protótipo para avaliação da biodegradabilidade?

Dessa forma, percebeu-se da inexistência de estudos que contemplassem testes de biodegradabilidade e Aprendizado de Máquina, o que torna esse o grande diferencial da proposta dessa dissertação. Diante disso, foram definidas duas estratégias de pesquisa, a primeira delas teve como objetivo a busca por trabalhos que realizaram o desenvolvimento de protótipos ou equipamentos destinados a ensaios de biodegradabilidade, já nessa etapa foi verificado a inexistência de trabalhos que aplicassem técnicas de Aprendizado de Máquina em ensaios de biodegradabilidade. A segunda estratégia de pesquisa buscou-se por tipos de técnicas aplicadas a séries temporais, no intuito de estudar e verificar quais algoritmos são mais adequados para a aplicação nos dados dessa dissertação.

A busca por trabalhos foi feita com base em palavras chaves, as palavras foram unidas em strings as quais foram aplicada em bibliotecas digitais de maior relevância como: ACM Digital Library, Google Scholar, IEEE Xplore Digital Library e Scienc Direct, esse busca foi realizada em janeiro de 2020, podendo demonstrar artigos diferentes dos aqui levantados, caso seja feita uma busca em nova data.

String utilizada para busca de equipamento e protótipos destinados a ensaios de

biodegradabilidade de materiais poliméricos:

("Biodegradability"OR "Biodegradation") AND ("equipment"OR "prototype") AND ("ASTM D5988"OR "ABNT 15448"OR "ISO 14855"OR "Standard")

String utilizada com foco em revisões sistemáticas de técnicas de Aprendizado de Máquina aplicadas em séries temporais para predição de dados:

("time series") AND ("machine learning") AND ("prediction"OR "forecasting") AND ("iot") AND ("sensor") AND ("review")

Em posse dessas strings, foram aplicados os quatro passos de seleção descritos e os trabalhos que descrevem uma metodologia de automatização de equipamentos para testes da biodegradabilidade são resumidos a seguir.

3.2 Análise dos trabalhos para metodologias automatizadas

Kijchavengjul et al. (2006) utilizam como base as normas ASTM D6400 e ISO 14855, em seu protótipo é realizado a automação de vinte e três reatores, os quais realizam os testes de Biodegradabilidade de forma simultânea, inicialmente é feita a redução dos níveis de CO_2 através da passagem de ar por soluções de NaOH, em seguida o ar passar por um reator com água para realizar a umidificação, o controle dessa umidade é feita através da medição do percentual de umidade presente no ar antes de passar pelos reatores em teste. Devido a umidade presente no ar o sistema passa por uma banho de óleo à 15 °C para evitar que umidade chegue até o analisador de CO_2 por infravermelho LI-840, foi utilizado um único analisador e a seleção do reator que será medido é feita através de uma conjunto de manifolds, cada reator é analisado em intervalos de 15 minutos, intercalados com passagem de ar limpo para remoção do CO_2 para uma nova análise. Antes do analisador de CO_2 foi instalado um medidor de fluxo de massa para determinação do fluxo de ar, que será utilizado nos cálculos do percentual de biodegradabilidade, o controle de acionamento de válvulas e medições são monitorados por um computador, no qual foi utilizado o software LabView da National Instruments para demonstração dos valores e controles de acionamento (KIJCHAVENGKUL et al., 2006).

Drímal et al. (2007) utilizaram três formas de medição de CO_2 em seu experimento, cromatografia, sensor infravermelho e titulação, com a finalidade de validar ambos os métodos. Os testes foram realizados a temperatura de 25 °C. A análise por cromatografia e sensor de infravermelho foram feitas a cada seis horas, a vazão utilizada foi de 150 mL/min, a umidade do solo foi mantida em 50 %UR, que foi ajustada no início dos testes, não deixando claro o controle ao longo do tempo. Ao final os autores concluem que é possível utilizar qualquer um dos três métodos para determinação do CO_2 , sendo necessário adaptar o sistema para permitir a realização de mais amostras simultaneamente (DŘÍMAL; HOFFMANN; DRUŽBÍK, 2007).

Kale et al. (2007) comparam três métodos de determinação da biodegradabilidade de materiais, um teste foi realizado utilizando o equipamento MODA da empresa Saída FDS INC, outro em ambiente real e um construindo um equipamento, para os métodos simulados foram utilizadas as normas ASTM D5338 e ISO 14855-1, em seu artigo os autores, os passos para desenvolvimento de um protótipo implementado, em seu equipamento o controle de umidade dos reatores de teste é feito através a passagem do ar por água deionizada, assim como o artigo resumido anteriormente, um medidor de umidade do ar instalado antes de entrar nos reatores de ensaio monitora o % de umidade relativa, nos caso de medições acima do desejado, o ar é desviado por um sistema de bypass, levando até ar seco para os ambientes de teste, foram utilizado 9 reatores todos eles com medidores de fluxo, ajustado a 60 mL/min, após passar pelos reatores de teste o ar entra em uma solução química, fazendo com que o CO_2 seja absorvido, o que possibilita que a medição seja feita através do método de titulação química. Ao final do artigo é demonstrado que existe algumas diferenças na leitura dos teores de CO_2 quando comparado entre os métodos padronizados e a exposição real dos materiais (KALE et al., 2007).

Funabashi et al. (2009) validaram em seu artigo o equipamento MODA (Analisador de Degradação Oxidativa Microbiana) desenvolvido para análise de Biodegradabilidade pela empresa Saída FDS INC. Esse equipamento foi construído tomando como base a normas ISO 14855-2 e ASTM D5338, o controle de umidificação é feito como nos demais experimentos acima mencionados, através da passagem de ar por um reator com água, o fluxo de ar é ajustado em 10 mL/min, o desse equipamento é que o ar umidificado entra pela parte de baixo dos reatores de teste e a medição do CO_2 gerado, é feita através da utilização de uma coluna de absorção de CO_2 (FUNABASHI; NINOMIYA; KUNIOKA, 2009).

Varga et al. (2009) automatizaram a realização de testes anaeróbicos para determinação da biodegradabilidade em materiais poliméricos, em seu trabalho foi utilizado uma câmara de temperatura regulada e como metodologia de medição de CO_2 foi utilizado transdutores de pressão, visto que os métodos anaeróbicos são realizados sem a circulação de ar entre a amostra de teste e o ambiente, é natural que exista o aumento de pressão em cada um dos sete reatores de teste que foram utilizados pelos autores utilizados, nesse caso é estudado a forma com que o aumento de pressão influencia no aumento de CO_2 . Assim como o primeiro artigo aqui resumido o software de aquisição de dados de (VARGAS; MORENO; MENDOZA, 2009) também foi o LabView.

Castellani et al. (2016) realizaram o desenvolvimento de um protótipo utilizando como base o método aeróbico, no qual é utilizada uma estufa para manter a temperatura de teste dentro das faixas pré-definidas pelas normas, foi instalado um bloco manifold para realizar o chaveamento de doze válvulas de controle de entrada de ar de doze reatores de teste. A umidificação do sistema também foi feita através um sistema de bypass, passando o ar pela água, mas não realizado nenhum tipo de medição da umidade relativa, o fluxo de ar para os reatores foi regulado em 20 L/h (aproximadamente 333 mL/min), as medições de CO_2 foram

feitas através de dois equipamentos de diferentes ranges de medição (0 à 3000 ppm e 3000 à 100000 ppm) os quais foram validados pelo método de titulação química (CASTELLANI et al., 2016).

Greene (2018) fizeram comparações com várias normas de biodegradabilidade, em ambientes simulando solo e água do mar, os autores construíram um dispositivo para realizar os testes seguindo a norma ASTM D5338, foram utilizados reatores de 3,8 L, e uma estufa para mantê-los a 58 °C, para medição do CO_2 foi utilizado um sensor de infravermelho, a umidade do solo foi monitorada e controlada em 50 %UR através da adição de água destilada. O software Labview foi utilizado para monitoramento das variáveis de teste, não foi especificado a quantidade de reatores nem o monitoramento dos fluxos de cada um (GREENE, 2018).

3.2.1 Comparação entre trabalhos

Com o objetivo de comparar trabalhos relacionados, é apresentado a Tabela 1 considerando cinco perspectivas: (i) controle de fluxo; (ii) número de embarcações; (iii) medição de CO_2 ; (iv) umidade do solo; (v) Software de monitoramento. Onde é possível ver claramente as diferenças entre cada um dos autores.

Tabela 1: Comparação entre os trabalhos relacionados. Percebe-se uma diversidade de parâmetros para as atuais metodologias de teste automatizado desenvolvidas. Nenhuma dessas metodologias utilizam o controle de umidade do solo por sensores e atuadores de forma automática. (NA - Não aplicado ou não especificado pelos autores)

Autor	Controle de fluxo	Número de reatores	Medição de CO_2	Umidade do solo	Software de Monitoramento
Kijchavengjul et al. (2006)	Individual por válvula e automática na entrada do sensor de CO_2	23	Sensor de infravermelho	Passagem do ar por água	Sim
Drímal et al. (2007)	NA	NA	Manual por titulação química e sensor de infravermelho	NA	Sim
Kale et al. (2007)	Individual por válvula manual	9	Manual por titulação química	Passagem do ar por água	Não
Funabashi et al. (2009)	Individual por rotâmetros	4	Manual, Coluna de absorção de CO_2	Passagem do ar por água	Não
Varga et al. (2009)	NA	7	Sensor de pressão	NA	Sim
Castellani et al. (2016)	Na entrada do sensor de CO_2	12	Sensor de infravermelho	Manual	Sim
Greene (2018)	NA	NA	Sensor de infravermelho	Manual	Sim

Fonte: elaborado pelo autor

Observando os dados da tabela 1 e os resumos dos trabalhos relacionados, percebe-se que os autores não utilizaram-se de nenhuma técnica para automatização dos ensaios de biodegradabilidade, conseqüentemente os seus sistemas são suscetíveis a falhas não contemplando uma automação eficaz, pois ambos possuem algum tipo de operação manual, um exemplo pode ser citado em relação ao abastecimento de água utilizada nos controles de umidade. Além, disso não verifica-se um controle de umidade por sensores, o que pode se tornar um problema, pois Borowik e Wyszowska (2016) fazem um estudo e mostram que o controle da umidade do solo é importante para o desenvolvimento de micro-organismos específicos. O modelo IoTBio irá preencher essa lacuna nos trabalhos da área, utilizando técnicas definidas e testadas cientificamente, permitindo a aquisição de dados para as variáveis envolvidas no processo para que seja possível a expansão desses estudos, integrando algoritmos de predição. Apesar dos trabalhos relacionados e aqui citados serem antigos, anteriores a 2016, ensaios da avaliação do percentual de biodegradabilidade é um assunto atual, Cardoso e Stefens (2020) tiveram um depósito de patente junto ao Instituto Nacional da Propriedade Industrial - INPI de um equipamento automatizado para análise do percentual de biodegradabilidade de materiais poliméricos em escala laboratorial (CARDOSO; STEFENS, 2020). Além disso Cardoso et. al. (2020) relatam em seu artigo a implementação de um equipamento de análise de biodegradabilidade desenvolvido no âmbito da Internet das Coisas, os autores desenvolveram um protótipo de teste e implementaram algoritmos de Aprendizado de Máquina utilizando o software Weka para prototipagem rápida dos algoritmos e verificação da possibilidade de previsão de valores futuros para ensaios do percentual de biodegradabilidade de materiais, os quais provaram que é possível a utilização de técnicas de previsão para determinação dos resultados antes mesmo do tempo real de ensaio (CARDOSO; COSTA; FIGUEIREDO, 2020) ¹.

3.3 Análise dos trabalhos para predição de séries temporais

Conforme já relatado não foi encontrado na literatura disponível nenhuma pesquisa relacionada com aplicação de algoritmos de predição em ensaios e testes de biodegradabilidade de materiais. Dessa forma foi realizada uma busca para verificar quais os tipos de técnicas mais indicadas à predição de resultados nesse tipo de séries de dados.

Na literatura identificamos revisões sistemáticas que analisam o estado da arte para séries temporais. Neste contexto, podemos destacar as revisões de Martínez-Álvarez et al. (2015), Deb et al. (2017), Fawaz et al. (2019), Chavan e Momin (2017) e Voyant et al. (2017), que fazem discussões sobre técnicas de Aprendizado de Máquina aplicado na previsão de séries temporais. Assim, com base nestas revisões direcionamos a discussão dos nossos trabalhos relacionados à séries temporais, que são resumidos a seguir:

Martínez-Álvarez et al. (2015) fazem uma revisão das principais técnicas de previsão,

¹https://www.sba.org.br/open_journal_systems/index.php/sba/article/view/998

aplicadas a séries temporais de consumo de energia elétrica. Os autores separam as técnicas em dois grandes grupos: lineares e não lineares. Para as lineares são descritas: AR, MA, ARMA, ARIMA, ARCH, GARCH or VAR e as não lineares: RNA, SVM, AG e KNN. Inicialmente é feita uma introdução para séries temporais muito similar ao feito no capítulo 2, item 2.3.2.5 dessa dissertação. Em seguida é mostrado as principais formas de avaliações de performance/acurácia para séries temporais, aonde são destacadas MAPE e RMSE. O principal objetivo dos autores é nortear pesquisadores sobre as técnicas disponíveis, servido como base para estudos iniciais na área de mineração de dados. A grande maioria dos trabalhos relatados em sua revisão, utilizam um horizonte de predição de para 1 ou 2 dias. No final é possível concluir que existem pouquíssimos trabalhos que aplicam KNN ou AG para predição de séries temporais. As técnicas mais usadas são RNA e SVM. Alguns modelos lineares também são usados, mas são menos precisos. Muitas vezes técnicas lineares são utilizadas para criação de uma linha base, sendo combinadas com outras técnicas mais complexas como RNA (MARTÍNEZ-ÁLVAREZ et al., 2015).

Deb et al. (2017) fazem uma comparação das técnicas de Aprendizado de Máquina aplicadas a séries temporais na previsão do consumo de energia elétrica em edifícios. Os autores analisam diversas técnicas isoladas e também alguns sistema híbridos, que unem mais de uma técnica. Os autores descrevem nove técnicas mais utilizadas para predição de consumo de energia elétrica, sendo elas em ordem crescente de utilização: Híbridas, ARIMA, SVM, RNA, Grey, Fuzzy, MA e ES, KNN, CBR. É feito um estudo aprofundado de comparação entre as técnicas demonstrando os trabalhos de maior significância para cada uma das técnicas. Além disso, é feito uma revisão de modelos que buscam a combinação entre mais de um algoritmo. Algumas tabelas com comparações são feitas apresentando vantagens e desvantagens (DEB et al., 2017).

- RNA: vantagens: capacidade de mapeamento preciso para as relações de entrada e saída, bom desempenho para séries não lineares, mais geral e flexível, desvantagens: depende da inicialização dos valores dos pesos, problema de mínimos locais, sobre ajuste difícil de generalizar;
- ARIMA: vantagens: lag e deslocamento de dados históricos, modelo de regressão com média móvel, fornecimento de intervalos de confiança nas previsões. Desvantagens: difícil identificação do modelo, não adequado para previsões de longo prazo, não captura totalmente os padrões não lineares da séries;
- SVM: vantagens: bom para montagem e generalização, bom desempenho para séries de longo prazo. Desvantagens: falta de transparência dos resultados, necessidade de alta capacidade computacional a medida que número de parâmetros aumenta;
- CBR: vantagens: Semelhante aos processos cognitivos humanos, não precisa encontrar regras entre os parâmetros do problema. Desvantagens: necessita de introdução de novos

aspectos, necessita de grande quantidade de dados;

- Fuzzy: vantagens: utiliza-se de regras de associação, bom para incertezas na previsão de cargas. Desvantagens: difíceis de ajustar quando a série possui ruídos, alta complexidade computacional e falta de estabilidade;
- Grey: vantagens: prevê com dados limitados e informações incompletas, fácil de calcular. Desvantagens: Inadequado no reconhecimento de componente aleatório, problema com a abordagem convencional de validação de modelo;
- MA e ES: vantagens: cálculos simples, baixo numero de obervações, transparência na abordagem. Desvantagens: resultados inferiores quando comparados com técnicas mais sofisticadas, Não é adequado para previsões de longo prazo e não lineares;
- KNN: vantagens: não necessita de etapa explícita de treinamento, fácil interpretação. Desvantagens: função é aproximada localmente, dificuldade para calculo do número exato de vizinhos próximos;
- Hibrido: vantagens: combinação de diferentes técnicas, Robusto para problemas complexos e geralmente melhora o desempenho. Desvantagens: complexidade do modelo, intensidade computacional, dificuldade de identificar quais as melhores combinações de métodos.

Voyant et al. (2017) fazem uma revisão sobre as principais técnicas de predição de resultados para controle de radiação solar para aplicação em painéis de energia solar. Os autores dividem os algoritmos de predição para séries temporais em três grupos. Os supervisionados são compostos por: regressão linear, modelos lineares generalizados e regressão não linear, SVN, Arvore de Decisão, KNN e Cadeia de Markov. Os não supervisionados: K-means, Clusterização, Gaussiano, Aprendizado em Conjunto, Boosting, Bagging, Subespaço aleatório. São descritos na revisão vários trabalhos e resultados com as técnicas mencionadas. O estudo feito demonstra que 79% dos estudos na área de pesquisa dos autores, utiliza algoritmos de RNA, o restante são divididos em Lógica Fuzzy, sistema de inferência neuro fuzzy adaptativo (ANFIS), wavelet de acoplamento de redes decomposição, Regressão e modelos híbridos. Na conclusão foi possível verificar que a literatura disponível demonstra que existem muitos fatores que influenciam nos resultados dos algoritmos de predição. Logo, é interessante testar mais de um método ou parâmetro. Os métodos de ARIMA e RNA possuem qualidade de previsão equivalentes, porem a flexibilidade de se trabalhar com dados não lineares, faz com que RNA tenham um preferência maior em relação ao ARIMA clássico (VOYANT et al., 2017).

3.3.1 Comparação entre trabalhos

Com o objetivo de comparar trabalhos relacionados para aplicações de algoritmos de predição em séries temporais, é apresentado a Tabela 2 considerando cinco perspectivas: (i) tempo de predição; (ii) aplicação; (iii) métricas de avaliação; (iv) técnicas mencionadas; (v) técnicas mais indicadas. Onde é possível perceber que ARIMA e RNA são as técnicas mais utilizadas por diversos pesquisadores que foram estudados nessas três revisões sistemáticas

Tabela 2: Comparação entre os trabalhos relacionados. Os trabalhos mostram as principais métricas de avaliações utilizada para previsão de séries temporais, além de apontar ARIMA e RNA como o estado da arte no que diz respeito a previsão de séries temporais

Autor	Tempo de predição	Aplicação	Métricas de avaliação	Técnicas mais indicadas
Martínez-Álvarez et al. (2015)	1 e 2 dias	Consumo de energia elétrica	MAPE e RMSE	RNA e SVM
Deb et al. (2017)	Dias, semana e até meses	Consumo de energia elétrica	R ²	Sistema híbrido ARIMA-RNA
Voyant et al. (2017)	Horas e Dias	Radiação solar para painéis solares	MBE, MAE, MSE, RMSE, MAPE	RNA e ARIMA
Khashei et al. (2011)	1, 6 e 12 meses	Taxas de câmbio, manchas solares e lince canadense	MAE, MSE, RMSE e MAPE	RNA, ARIMA e Híbrido ARIMA-RNA
Chavan e Momin (2017)	anos	Previsão do tempo	RMSE	ARIMA

Fonte: elaborado pelo autor

Além das revisões sistemáticas mencionadas acima, foram encontrados seis trabalhos os quais aplicaram técnicas de predição em séries temporais. Esses trabalhos mostram que o estado da arte para predição de séries temporais esta na aplicação de algoritmos de ARIMA e RNA:

Tealeab (2018) faz uma revisão sistemática com o intuito de estudar as diferentes técnicas de RNA aplicadas na previsão de dados em séries temporais. No início de sua revisão o autor faz menção as vantagens da utilização de modelos com Redes Neurais Artificiais sobre modelos de média móvel (ARIMA). Os modelos de ARIMA são vulneráveis quando aplicados em séries de dados que possuem comportamento não lineares, o que impulsionou diversos pesquisadores pela busca de novas metodologias de predições. A literatura disponível mostra que uma ampla gama de modelos com diferentes representações matemáticas não lineares, como modelos baseados em esquemas e diferentes tipos de RNA. Diante disso, o autor faz uma busca tomando como base respostas para sete questões de pesquisa que julgou importantes na avaliação de modelos de previsão. Esses questionamentos buscam encontrar trabalhos que tenham: uma boa formulação matemática, processo de estimativa de parâmetros, critérios para seleção de variáveis, modelo de complexidade, avaliação e diagnóstico para o modelo, viabilidade em aplicações de casos reais e especificações detalhadas de projeto. Com base nas respostas de suas questões de pesquisa os autores chegam a conclusão que foram desenvolvidos diversos novos modelos de RNA para aplicação em séries temporais e de maneira geral foi observado que os modelos apresentados não satisfazem completamente um procedimento sistemático para construção de um modelo de RNA. (TEALAB, 2018)

Fawaz et al. (2019) estudam o estado da arte de algoritmos de aprendizado profundo apresentando uma visão geral para as técnicas mais bem sucedidas. Na introdução os autores fazem um breve resumo da história sobre algoritmos de predição para séries temporais. KNN era uma das técnicas mais utilizadas, porem foi provado que não existe uma única medida de distância entre os vizinhos, fazendo com que o agrupamento de classificadores de KNN individuais superavam a avaliações individuais, dessa forma os algoritmos de SVM passaram a ser estudados superando definitivamente a técnica de KNN. São referenciados diferentes estudos, que mostram que ao longo do tempo, a complexidade dos dados exigiu por técnicas mais complexas. Em 2015 o estudo de Deep Learning passaram a ser estudados e tiveram desde então atenção de diversos pesquisadores, os quais implementam e testam diferentes tipos de aplicações. É feito um estudo aprofundado sobre nove aplicações de Redes Neurais Convolucionais, apresentando diferentes resultados, tempos de compilação e acurácia, o que demonstra um estado da arte no estudo de predição de séries temporais utilizando RNA (FAWAZ et al., 2019).

Chavan e Momin (2017) escreveram um artigo sobre a aplicação de séries temporais na previsão do tempo. Em seu trabalho os autores utilizaram técnicas de IoT, aplicada em dispositivos de baixo consumo de energia para captar variáveis meteorológicas como: temperatura, umidade e pressão. Os dados eram armazenados por uma placa Raspberry, os quais eram então utilizados para previsão de chuva. Foram testadas as técnicas de Regressão

Linear, Regressão múltipla, SVR e ARIMA. Os autores concluem que o algoritmo de ARIMA é o mais adequado em sua aplicação, uma vez que tiveram resultados de RMSE menores demonstrando que ARIMA teve mais acertos ao longo das previsões (CHAVAN; MOMIN, 2017).

Ahmed et al. (2010) fazem uma comparação entre oito modelos de Aprendizado de Máquina aplicados a séries temporais, na abordagem dos autores o modelo de RNA são os com melhores resultados para previsões de séries temporais (AHMED et al., 2010). Zhang (2003) fez um estudo da aplicação de séries temporais para previsão de meteorologia aplicando um modelo híbrido de ARIMA e RNA, o autor mostra que a fusão de ambos os modelos melhora os resultados nas previsões realizadas, o mesmo descreve ainda que não existe um modelo universal para utilização de previsão de séries temporais, nesse caso existe a necessidade da realização de testes para verificar qual algoritmo se adapta melhor aos dados disponíveis (ZHANG, 2003). Khashei et al. (2011) também testaram os modelos de ARIMA e RNA para séries temporais, com diferentes datasets, além disso os autores propõe um modelo novo para fusão entre os métodos, e demonstram que nem sempre a utilização de um método ou a fusão de ambos possui resultados aceitáveis, sendo necessário um estudo e testes sobre o dataset que vai ser usado para verificar a efetividade de cada técnicas (KHASHEI; BIJARI, 2011).

Com base nos trabalhos resumidos nesse capítulo é possível chegar a algumas considerações parciais, que são descritas na próximo item.

3.4 Considerações parciais

Metodologias de testes automatizado desenvolvidos nessa área, não contemplam um controle de umidade do solo por sensores, mantendo essa operação ainda dependente de operadores. O controle de umidade do solo ou é feita de forma manual ou através da passagem do ar por um frasco com água, mantendo o abastecimento dessa água manualmente. A passagem de ar pela água para humificação deixa dúvidas com relação a efetividade no controle de umidade do solo. Nenhum trabalho da área realizou implementações de algoritmos de Aprendizado de Máquina. Dessa forma realizou-se um estudo para verificar quais algoritmos mais utilizados para predição de séries temporais, verifico-se que ARIMA e RNA são os mais utilizados para séries temporais em diferentes áreas. Sendo assim existem duas grandes diferenças entre a proposta dessa dissertação e os trabalhos resumidos:

- Aplicação de técnicas científicas para proposição de uma nova metodologia de teste de biodegradabilidade que permita a aplicação de algoritmos de predição para reformulação dos tempos reais necessários para avaliação da biodegradabilidade de materiais;
- Implementação de algoritmos de ARIMA e RNA para predição de séries temporais aplicadas na determinação da biodegradabilidade de materiais poliméricos em equipamentos de ensaios laboratoriais.

Cardoso et. al. (2020) já implementaram algoritmos de Aprendizado de Máquina para previsão dos resultados de ensaios do percentual de biodegradabilidade, mostrando que é viável prever valores futuros para esse tipo de dados, porém os autores trabalharam em um software limitado, não permitindo uma otimização adequada e nem a aplicação de diferentes arquiteturas de RNA, como a arquitetura LSTM (CARDOSO; COSTA; FIGUEIREDO, 2020). Sendo assim, o modelo proposto irá contar com combinação dos conceitos de IoT, Indústria 4.0 e Aprendizado de Máquina, aonde são destacadas as seguintes oportunidades de pesquisa com o desenvolvimento dessa dissertação:

- 1) Definição de um modelo totalmente automatizado, que não necessite da intervenção humana durante o período de teste, seguindo os conceitos atuais de IoT e indústria 4.0;
- 2) Estudo da eficácia do controle de umidade do solo na realização dos testes de verificação da biodegradabilidade;
- 3) Implementação de um protótipo utilizando sensores de baixo custo;
- 4) Elaboração e estudo de um modelo de algoritmos de Aprendizado de Máquina para redução do tempo real de teste.

No próximo Capítulo, serão descritos as implementações para o estudo e definições da metodologia de ensaio a ser seguida. A partir da metodologia proposta, serão apresentados os resultados e comparações importantes para a construção de um equipamento. O equipamento será responsável por gerenciar de forma autônoma os ensaios de biodegradabilidade de materiais poliméricos.

4 MODELO PROPOSTO: IOTBIO

Nessa dissertação de mestrado é proposto um modelo denominado como IoTBio. O IoTBio tem como função a realização de testes para verificação do percentual de biodegradabilidade de materiais poliméricos em escala laboratorial sem a necessidade de realizar o testes com o período de dias completo, os quais variam de 90 a 180 dias. Para isso, foram aplicadas técnicas de IoT e Aprendizado de Máquina. A utilização dessas técnicas buscam preencher lacunas que existe nos trabalhos já desenvolvidos para automatização de testes da biodegradabilidade de materiais poliméricos, onde não é possível localizar na literatura disponível trabalhos que realizam a aplicação de técnicas científicas, nem aplicação de técnicas de Aprendizado de Máquina na previsão de resultados do percentual de biodegradabilidade em escala laboratorial. A automatização com o uso de sensores e atuadores possibilitam a realização dos testes de forma autônoma, além de possibilitar a coleta de dados das variáveis envolvidas nos testes. O armazenamento desses dados torna possível a aplicação de algoritmos de predição com o intuito de reduzir os tempos reais de teste. Nesse capítulo serão apresentados as decisões de projeto e detalhes para implementação do modelo IoTBio.

4.1 Decisões de Projeto

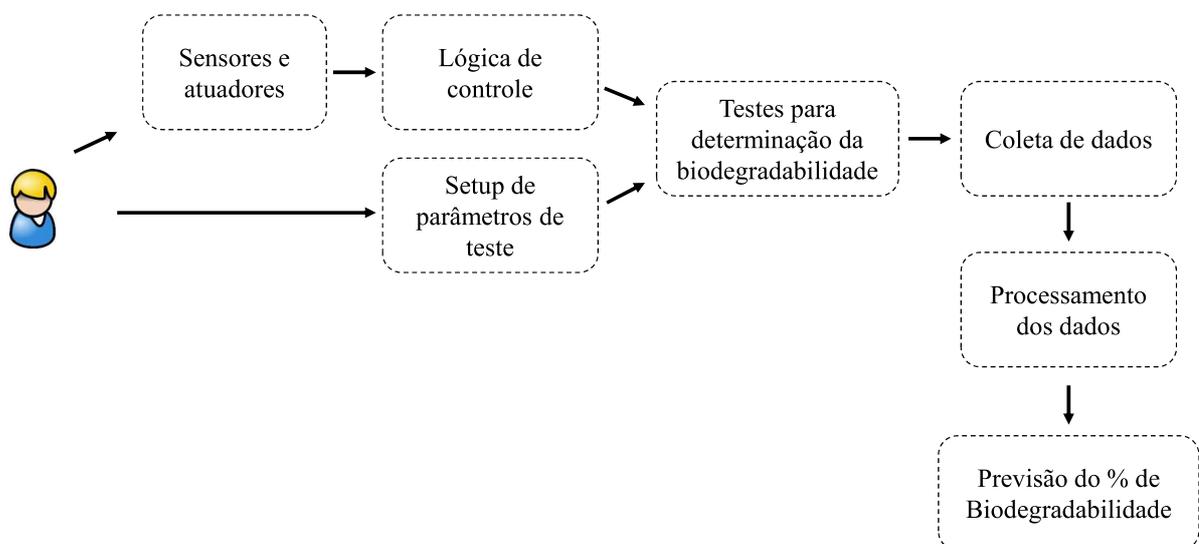
O IoTBio parte de duas premissas. Primeiro, a realização dos testes deve ser totalmente automatizado para minimizar a intervenção de operadores durante a realização dos testes de biodegradabilidade. Segundo, os dados coletados serão utilizados para implementação de algoritmos de Aprendizado de Máquina, com o objetivo de redefinir os tempos de teste necessário para realização dos testes de determinação do percentual de biodegradabilidade, permitindo a realização de uma maior quantidade de ensaios e com custo reduzido, alavancando o desenvolvimento de novos materiais biodegradáveis. Sendo assim, faz parte do escopo do IoTBio:

- A automatização deve ser feita através da aplicação de sensores e atuadores, permitindo a coleta de dados oriundas dos ensaios para que possam ser utilizados posteriormente;
- Os sensores e atuadores utilizados no IoTBio devem ser de baixo custo e devem possuir exatidão e precisão adequada para realização de ensaios de determinação do percentual de biodegradabilidade de acordo com as normas ABNT NBR 15448-2, ASTM D5988 e ISO 14855-1;
- Deve ser possível a realização da determinação do percentual de biodegradabilidade em pelo menos 4 amostras de forma simultânea, o que corresponde a no mínimo 18 frascos de ensaio, sendo: 3 para o composto em teste (solo), 3 para material de referência e os demais frascos para depósito das amostras em teste, sendo realizados cada amostra em triplicata;

- A implementação deve possuir o menor custo possível no que diz respeito aos materiais utilizados;
- Todos os sensores devem ser calibrados para garantir a exatidão e precisão necessária para atendimento das normas acima mencionadas;
- Os algoritmos de aprendizado de máquina devem ter a capacidade de prever resultados antes mesmo do tempo total de testes, sendo capazes de alcançar erros máximos de 20 % entre valores reais e valores previstos.

Com base nas premissas definidas, a Figura 24 ilustra uma visão geral do modelo proposto. Espera-se que analistas façam a instalação de sensores para aquisição das variáveis envolvidas no processo (temperatura, umidade do solo, fluxo de ar e medição de CO_2), esses sensores devem ser controlados por um dispositivo adequado para esse fim, sugere-se a utilização de um dispositivos microprocessado (CLP ou microcontrolador). Temperatura, fluxo de ar e umidade do solo, devem ser controlados através de atuadores, buscando atender os parâmetros de teste definidos pelas normas ABNT NBR 15448-2, ASTM D5988 e ISO 14855-1. Um operador deve fazer o setup para definição dessas variáveis de testes, as quais podem mudam de acordo com a norma a ser atendida. Em seguida, o sistema entra em funcionamento e de acordo com a emissão CO_2 ao longo do tempo, é feita a determinação do percentual de biodegradabilidade de forma automática. Os dados coletados pelos sensores são armazenados e futuramente utilizados para implementação dos algoritmos responsáveis pela previsão do percentual de biodegradabilidade.

Figura 24: Visão geral do modelo IoTBio

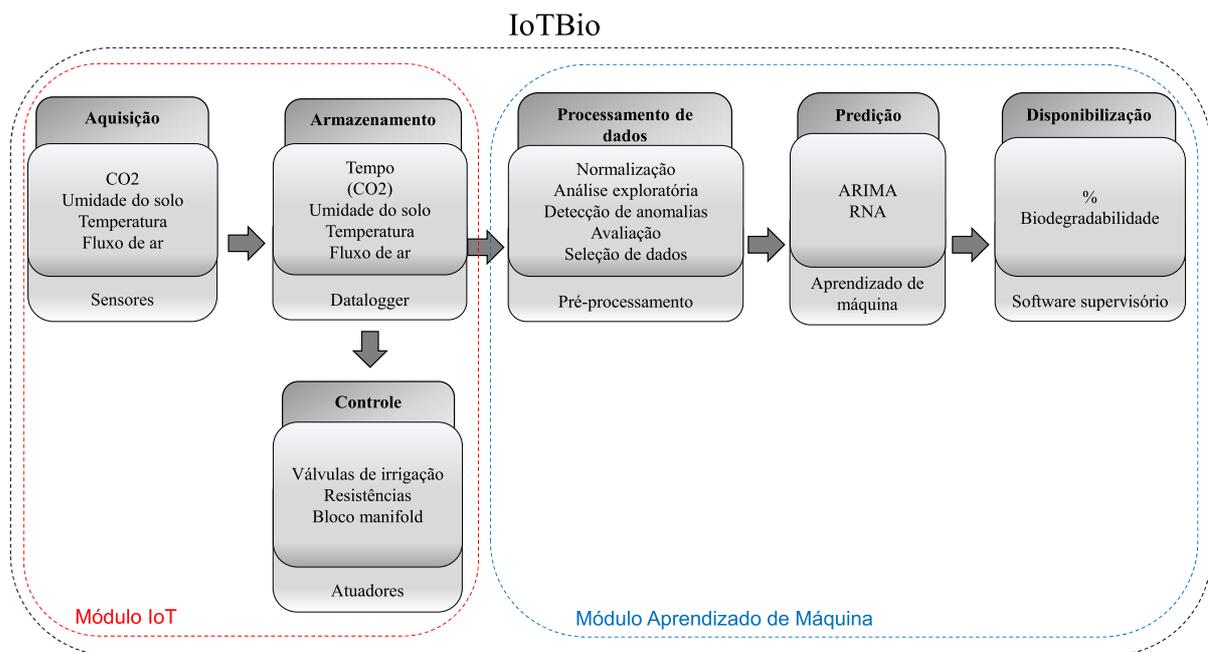


Fonte: elaborado pelo autor

4.2 IoTBio

O IoTBio realiza a integração entre sensores e atuadores de um protótipo para determinação do percentual da biodegradabilidade de materiais poliméricos. Com base nas definições de projeto apresentadas, o IoTBio foi dividido em dois módulos. O primeiro módulo, é constituído de um sistema IoT, que faz a integração de sensores, atuadores e software supervisorio. O segundo módulo, é composto pelos algoritmos de Aprendizado de Máquina, destinados a previsão dos resultados dos testes de biodegradabilidade. O modelo IoTBio é mostrado na Figura 25.

Figura 25: Modelo IoTBio proposto: o modelo é composto de dois grande módulos, o primeiro trata-se do módulo de IoT o qual é composto por sensores e atuadores. O segundo módulo trata-se do módulo de Aprendizado de Máquina, onde são realizados os tratamentos dos dados dos ensaios de biodegradabilidade de materiais poliméricos e aplicação das técnicas de ARIMA e RNA, permitindo a determinação do percentual de biodegradabilidade do material em teste antes do final do tempo real de teste



Fonte: elaborado pelo autor

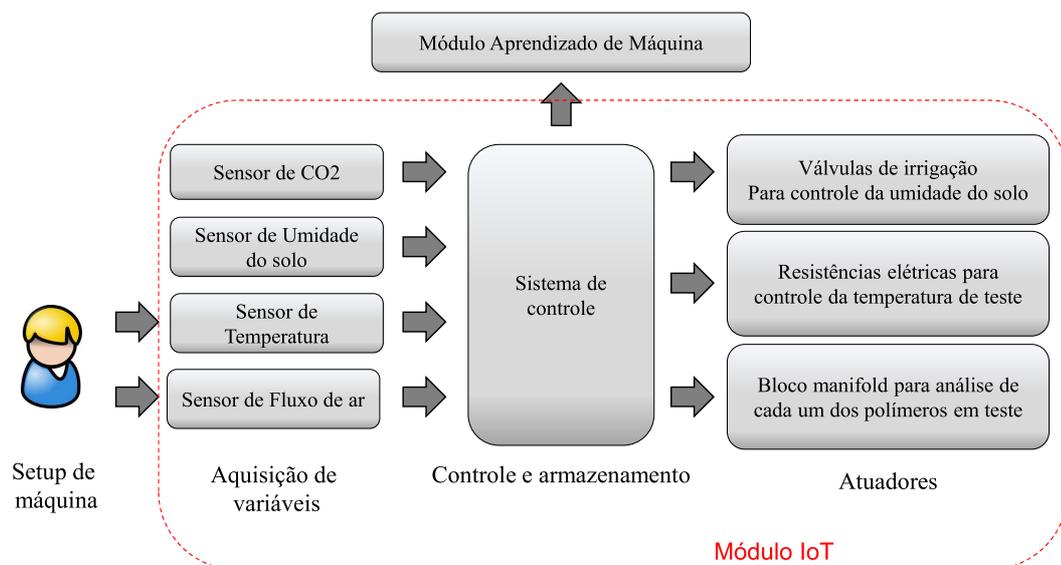
4.2.1 Módulo IoT

Muitos são os benefícios da utilização de sistemas automatizados e IoT (WOLLSCHLAEGER; SAUTER; JASPERNEITE, 2017). Uma das vantagens da utilização de sensores e atuadores automáticos é a redução dos tempos de hora-homem na operação de um determinado sistema, máquina ou equipamento (SINGH; KAPOOR, 2017). Outra vantagem está no armazenamento de variáveis de processo, possibilitando a integração desses dados com sistemas computacionais para aplicação das mais diversas técnicas de análise (ALPAYDIN,

2020). Assim, processos longos desempenham atividades com maior segurança, confiabilidade, precisão e exatidão. Dessa forma é proposto o modelo IoTBio. Um modelo automatizado que emprega técnicas de automação e IoT, possibilitando a operação automática de ensaios para determinação do percentual da biodegradabilidade de materiais poliméricos. O emprego dessas técnicas, permitem que seja possível o armazenamento do valor das variáveis envolvidas nos ensaios de biodegradabilidade. Através de técnicas estatísticas e sistemas computacionais, esses dados são estudados, tornando possível a verificação de seus comportamentos. Com base nessas características são aplicados filtros. Para que então, seja possível a aplicação de técnicas de Aprendizado de Máquina.

O módulo de IoT é de fundamental importância no desenvolvimento desse trabalho, é nele onde as informações são recebidas, processadas e armazenadas. A arquitetura do módulo é apresentado na Figura 26.

Figura 26: Arquitetura proposta para o módulo de IoT



Fonte: elaborado pelo autor

- **Setup de máquina:** inicialmente, operadores devem fazer um setup de máquina, ajustando os valores de temperatura e fluxo de ar de acordo com a norma a ser atendida na determinação do percentual de biodegradabilidade. O fluxo de ar de todos os reatores devem ser ajustados, um a um. As tolerâncias para as medições são apresentadas no próximo item;
- **Aquisição:** a utilização de sensores permitem a implementação de um sistema automatizado, os mesmos são responsáveis por converter grandezas físicas em sinais elétricos, possibilitando o controle sobre as variáveis de processo, esse controle garante a realização dos testes de biodegradabilidade, possibilitando exatidão e precisão nos resultados. Dessa forma serão utilizados sensores para medição e controle das seguintes

grandezas: umidade do solo (controlada em $50 \%UR \pm 5 \%UR$), temperatura (controlada em $58 \text{ }^\circ\text{C} \pm 2 \text{ }^\circ\text{C}$), fluxo de ar (controlado em $400 \text{ mL/min} \pm 50 \text{ mL/min}$), CO_2 (apenas medição, pois é gerado de acordo com o percentual de biodegradabilidade do material em teste);

- Controle: possibilitam o controle das variáveis já mencionadas, o controle é feito através de atuadores, os quais tratam-se de válvulas, utilizadas para controle automático da umidade do solo e direcionamento do fluxo de ar de cada reatores de teste para medição do CO_2 gerado. A utilização de sistemas micro controlados facilitam a definição das ações que devem ser tomadas, o mesmo irá fazer o acionamento dos atuadores do sistema, bem como a recepção das informações dos sensores;
- Armazenamento: os sistemas de supervisão são capazes de monitorar e controlar processos em tempo real, fornecendo uma grande quantidade de dados e informações que auxiliam na tomada de decisões. A grande quantidade de dados gerados por sistemas de IoT necessitou do desenvolvimento de programas capazes de armazenar e gerenciar as informações, sendo fundamentais para gerir dados que serão utilizados futuramente.

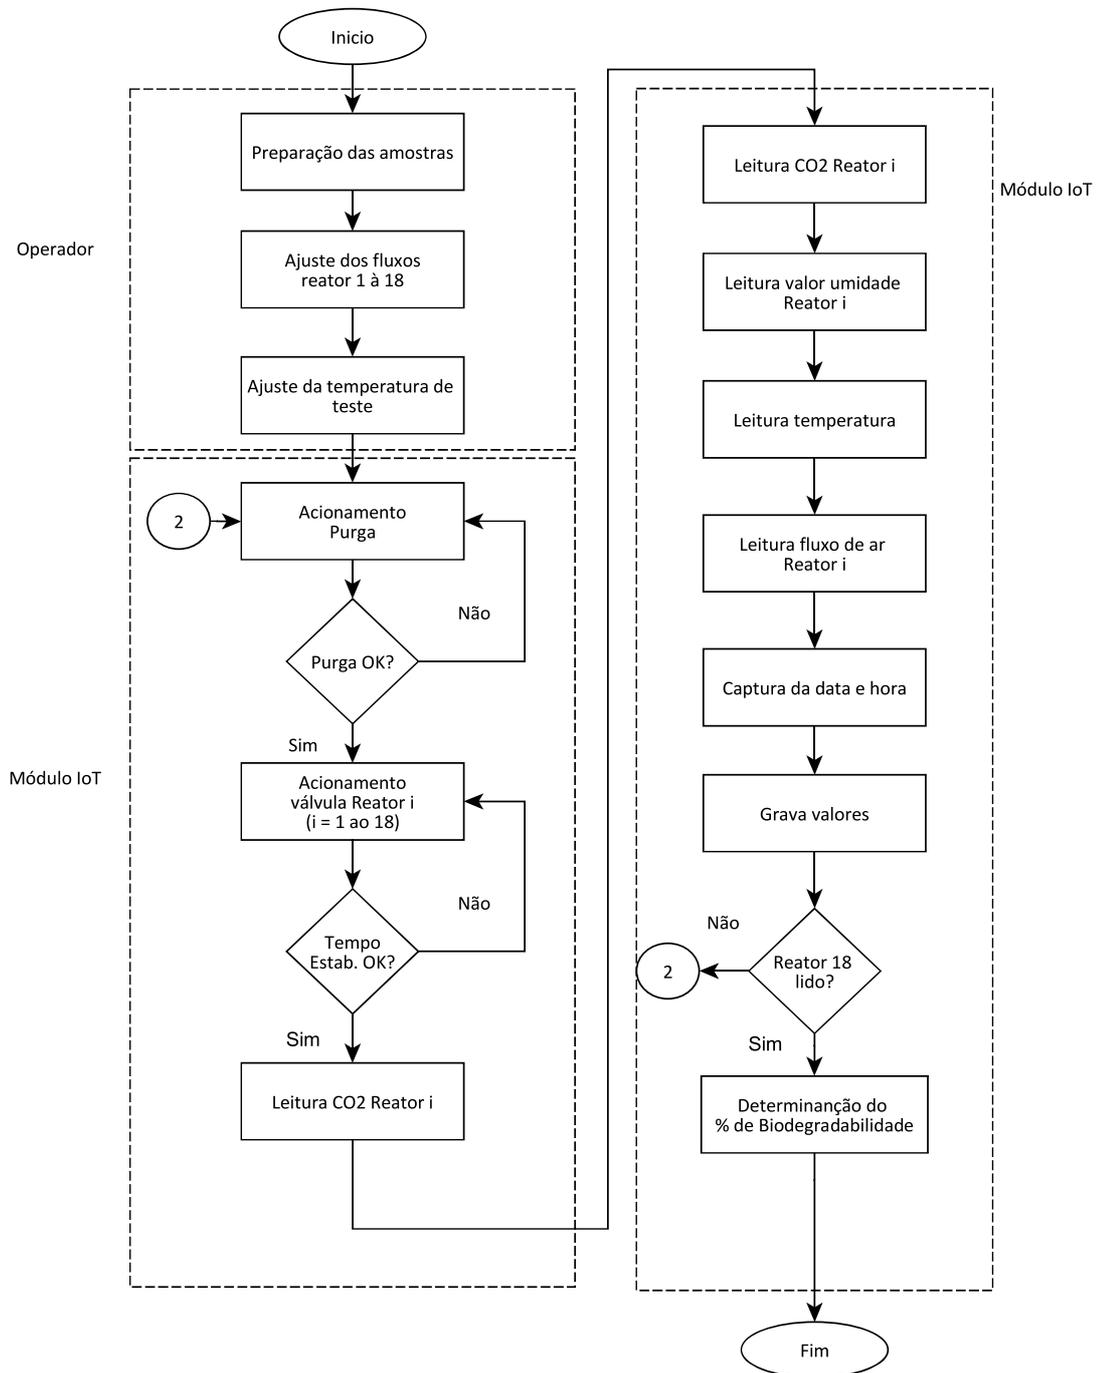
Todos os itens acima descritos formam o módulo de IoT do modelo proposto, possibilitando o controle automatizado das variáveis envolvidas nos testes de biodegradabilidade, permitindo o funcionamento e implementação do módulo de aprendizado de máquina.

4.2.1.1 Funcionamento do Módulo IoT

O funcionamento do Módulo de Aprendizagem de Máquina é descrito a seguir e deve atender o fluxo ilustrado na Figura 27:

- Inicialmente existe uma interação do operador, onde o mesmo necessita de realizar a preparação das amostras e composto os quais serão testados;
- Em seguida o operado deve fazer o ajuste de cada um dos fluxos de ar de cada recipiente onde está os polímeros de testes, esses recipientes são chamados de reatores;
- Após a regulação do fluxo de ar a última intervenção do operador é no setup de temperatura;
- A partir do ajuste das variáveis de testes o protótipo entra em operação automática. Inicialmente é feito o acionamento de uma válvula de purga, durante 20 minutos para limpeza do sistema;
- Após feita a purga do sistema é acionado a válvula de direcionamento do ar para análise dos polímeros de teste, iniciando pelo reator 1, o gás passa pelo sistema por 20 minutos de forma a homogeneizar o gás de análise;

Figura 27: Fluxo de funcionamento do módulo IoT



Fonte: elaborado pelo autor

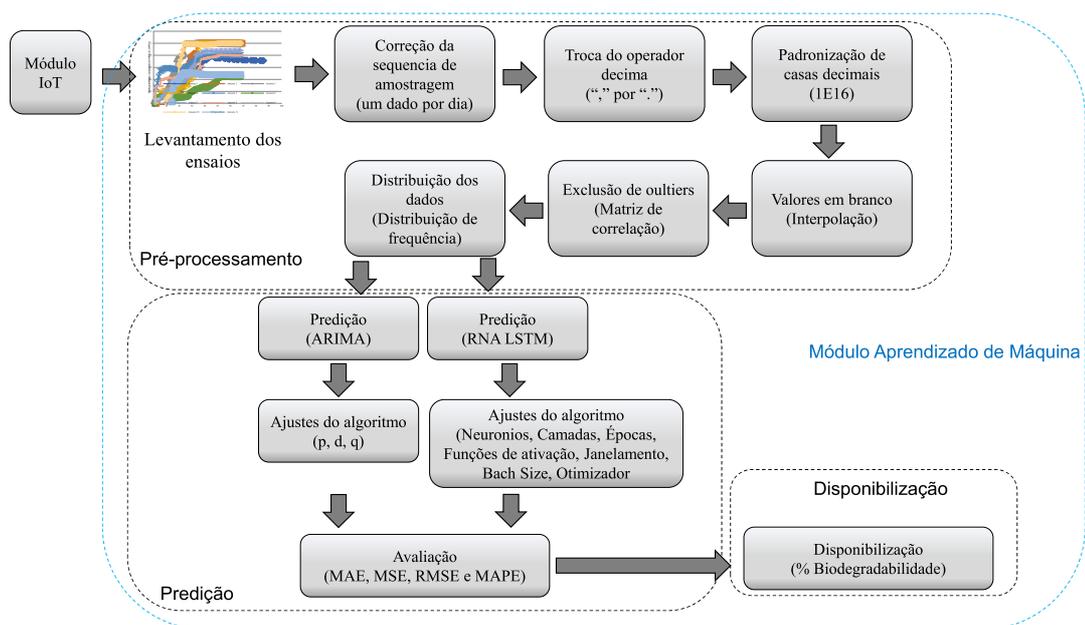
- Em seguida é feita a medição de 10 leituras do sensor de CO_2 pelo sistema microcontrolado, uma média desses valores é armazenado em uma variável, correspondente ao número do reator de análise;
- Após a medição do gás, é feita a medição da umidade do solo, a umidade também é armazenada em uma variável correspondente ao reator o qual foi realizado a leitura;

- Logo depois é realizada a leitura do valor de temperatura do ensaio e armazenada em uma variável;
- E por último é feita a leitura do fluxo de ar de entrada do sensor de CO_2 , e salvo em uma variável;
- Após a leitura de todos os sensores do reator de número n , os valores correspondentes são armazenados, junto com o exato momento em que os dados foram recebidos (data, hora, minutos e segundos);
- Serão utilizados 18 reatores de teste, possibilitando a realização dos testes do percentual de biodegradabilidade em 4 amostras simultaneamente. Se o último reator (reator de número 18) foi lido é finalizado um ciclo completo de leitura das variáveis, caso contrário o sistema retorna a purga, e começa o ciclo de leitura de um novo reator, ou seja, reator $n + 1$, até que o reator de número 18 seja lido.

4.2.2 Módulo de Aprendizado de Máquina

O segundo módulo é utilizado para implementação dos algoritmos de Aprendizado de Máquina, é aqui onde são feitas as previsões do percentual de biodegradabilidade, permitindo a redução dos tempos reais de teste os quais podem variar entre 90 e 180 dias. Na sequência é apresentado a arquitetura proposta para o Módulo de Aprendizado de Máquina, Figura 28 e a explicação do mesmo.

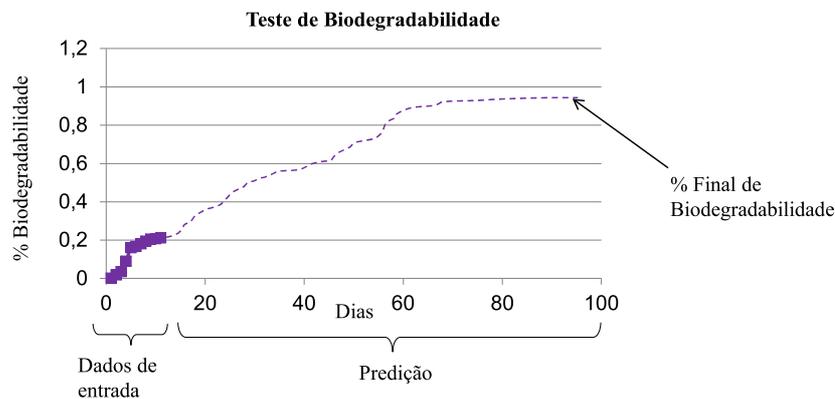
Figura 28: Arquitetura proposta para o módulo de Aprendizado de Máquina



Fonte: elaborado pelo autor

- **Processamento de Dados:** é responsável por todas as manipulações matemáticas e estatísticas necessárias para preparação dos dados de testes já realizados. Essa preparação dos dados irá possibilitar a implementação e correto funcionamento dos algoritmos de Aprendizado de Máquina;
- **Predição:** trata-se da parte onde os resultados são processados e expandidos conforme tempo pré-determinado, ou seja, aqui será realizado a implementação dos algoritmos de Aprendizado de Máquina, sendo eles ARIMA e Redes Neurais Artificiais, para que seja possível prever resultados dos testes antes mesmo dos períodos reais que podem variar de 90 à 180 dias. A previsão será feita tomando como base os dias de teste que já passaram para o polímero atualmente em teste, a Figura 29 faz uma ilustração do que se espera que aconteça nesta parte do IoTBio:

Figura 29: Demonstração de Funcionamento das previsões



Fonte: elaborado pelo autor

- **Disponibilização:** os resultados das variáveis de teste e o percentual de biodegradabilidade dos polímeros em teste no IoTBio deverão ser disponibilizados através de um software de supervisão.

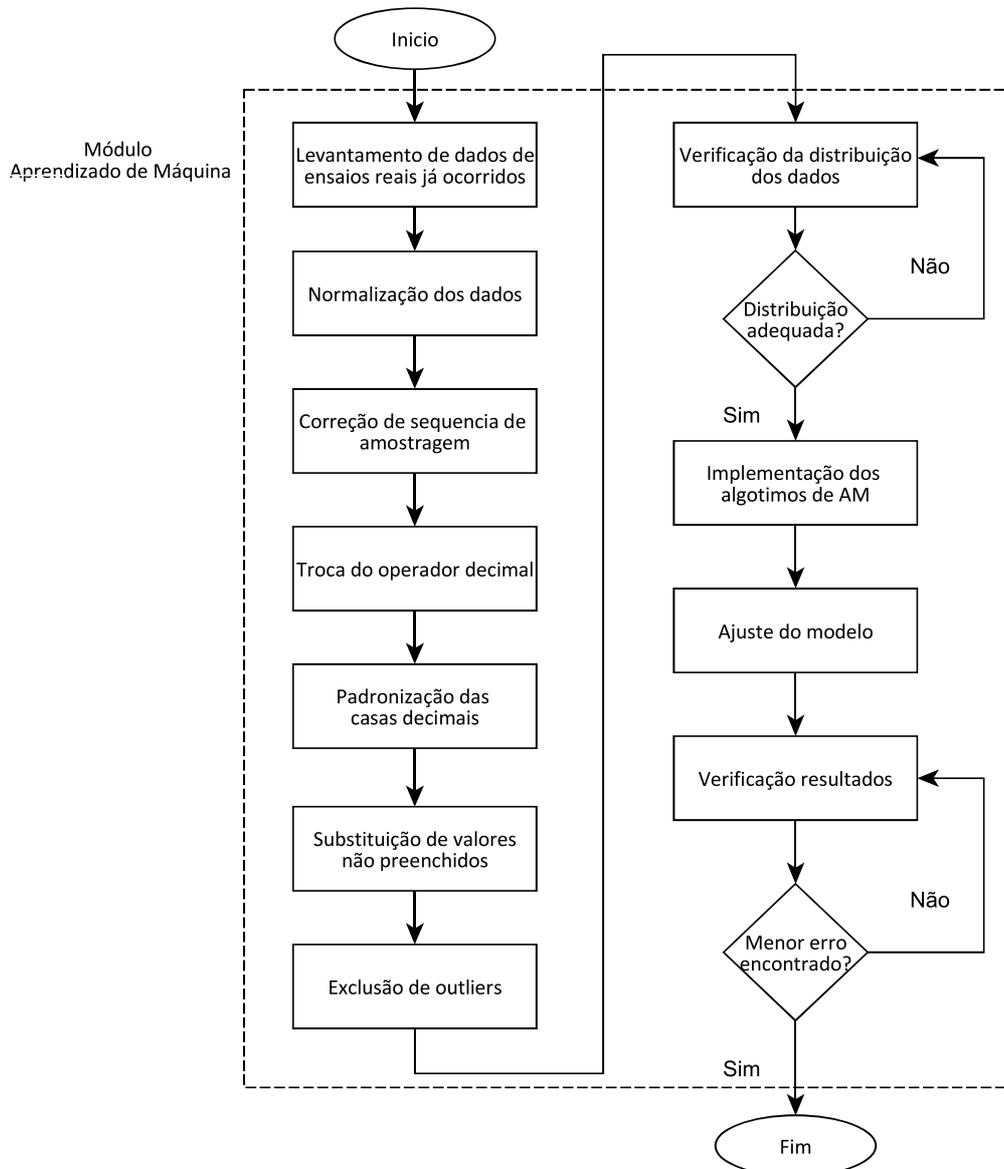
Esses itens formam o módulo de Aprendizado de Máquina do modelo proposto, possibilitando o tratamento dos dados de testes reais do percentual de biodegradabilidade e a implementação dos algoritmos de Aprendizado de Máquina, destinados a previsão dos testes com tempo reduzido.

4.2.2.1 Funcionamento do Módulo de Aprendizado de Máquina

O funcionamento do Módulo de Aprendizagem de Máquina é descrito a seguir e deve atender o fluxo ilustrado na Figura 30:

- Inicialmente foram levantados os resultados de ensaios reais já realizados para determinação do percentual de biodegradabilidade;

Figura 30: Fluxo de funcionamento do módulo Aprendizado de Máquina



Fonte: elaborado pelo autor

- Os dados foram normalizados tendo como referência valor mínimo zero "0" e valor máximo um "1", a normalização foi feita nessa faixa devido ao fato dos dados serem crescentes e terem valores reais em percentuais de zero a cem por cento;
- Para que seja possível a implementação dos algoritmos é necessário que a sequência de valores seja contínua, nesse caso os valores faltantes de dias de teste, foram preenchidos com interpolações entre os valores os quais se tinha, garantindo dessa forma uma sequência contínua de dias de amostragem;
- Os resultados dos testes reais, são definidos utilizando virgula "," como operador de separação decimal, dessa forma foi necessário a troca do operador para ponto ".";

- Os dados devem possuir quantidade de casas decimais iguais;
- É necessário a verificação de possíveis dados considerados fora de padrão, esses dados devem ser excluídos para não influenciar negativamente os algoritmos;
- Uma grande quantidade de dados nem sempre pode ser bom para implementação de algoritmos de Aprendizado de Máquina, uma vez que muitos dados tenham características parecidas e outros não, pode acontecer o chamado de overtraining, ou seja, sobre treinamento. Vimos que uma rede neural funciona de forma similar ao cérebro humana, nesse caso, o processo de aprendizagem tem que ser conciso. Sabe-se que os dados do percentual de biodegradabilidade variam de zero a cem por cento, nesse caso teremos materiais os quais possuem diferentes percentuais de biodegradabilidade. A verificação da distribuição desses dados nos mostra se tem um equilíbrio entre os valores máximos desses dados. Caso os dados estejam desequilibrados é necessário a aplicação de técnicas para seleção dos melhores dados a serem utilizados;
- Após realizado o pré-processamento os dados estão prontos para serem utilizados na aplicação dos algoritmos de Aprendizado de Máquina;
- Deve ser realizado ajustes até se atingir os menores erros entre valores reais e valores previstos;

Definidos os dois módulos do modelo IoTBio no próximo capítulo serão detalhados os materiais e métodos que foram utilizados para implementação do mesmo. Sendo detalhado tanto a parte do módulo de IoT quanto do módulo de Aprendizado de Máquina.

5 MATERIAIS E MÉTODOS

Com base nos conhecimentos adquiridos através das pesquisas e trabalhos relacionados, neste capítulo são apresentados os materiais e métodos utilizados para implementação do modelo IoT_{BIO}, descrevendo a seleção e teste dos sensores de baixo custo e das técnicas que serão aplicadas.

5.1 Protótipo de Hardware Desenvolvido

Sensores são dispositivos eletrônicos capazes de converter grandezas físicas em sinais elétricos (corrente ou tensão). Em conjunto com os sensores estão os atuadores, itens capazes de realizar a manipulação das grandezas físicas como: resistências elétricas e sistemas de refrigeração para controle de temperatura, umidificadores ou resfriadores para controle de umidade, dampers e controle de velocidade de motores para controle de fluxo, válvulas para controle de pressão e fluxo, entre outros. A utilização de sensores faz com se tenha um controle preciso sobre variáveis de processos. Dessa forma, o módulo IoT do modelo IoT_{Bio}, é composto por um protótipo composto por sensores e atuadores, esse protótipo será utilizado para avaliação do IoT_{Bio}. Nos próximos itens serão descritos os passos para seleção dos sensores e atuadores que irão compor o protótipo.

5.1.1 Seletividade de Sensores

Hoje percebe-se uma grande gama de sensores com valores e aplicações bastante variáveis. Diante disso foi necessário buscar pelo melhor custo/benefício na seleção de cada um dos itens necessários para o desenvolvimento do protótipo. Como um dos objetivos é a montagem com baixo custo, foram necessários alguns testes com diferentes sensores para determinação da melhor escolha.

5.1.1.1 Sensor de CO_2

O sensor de CO_2 é o principal dispositivo do projeto, pois é com base nas emissões de CO_2 que é determinado o percentual de biodegradabilidade dos materiais em teste. Nesse caso, foi necessário um estudo minucioso para escolha do mesmo. Com base nos trabalhos relatados foi possível verificar os mais diversos sensores com as mais diversas formas de medição, sendo eles por infravermelho, coluna de absorção, acumulo de pressão e ainda por cromatografia gasosa, dessa forma foi necessário a realização de um estudo levando em consideração alguns sensores hoje disponíveis para determinação de CO_2 :

- Cromatógrafo: este equipamento é portátil, este equipamento analisa a composição química dos gases, a partir de uma curva de calibração, foi utilizado um cromatógrafo da

marca Q-Micro, modelo DynamiQ-S series, este equipamento é dado como padrão de referência para analisar o conteúdo de CO_2 , juntamente com os gases padrão necessários para a realização da curva de calibração do equipamento, um investimento aproximado de R\$ 240.000,00 (duzentos e quarenta e cinco mil reais);

- Sensor MQ135: sensor resistivo utilizado para detecção de gases tóxicos, possui alimentação de 5 Vdc e saída analógica de 0 a 5 Vdc, investimento de aproximadamente R\$ 30,00 (trinta reais);
- Sensor Mh-z14a: sensor infravermelho, também alimentado por 5 Vdc, o sensor possui comunicação serial, PWM e analógica, possibilitando também calibração zero via comunicação serial, um investimento de aproximadamente R\$ 160,00 (cento e sessenta reais);
- Sensor CCS811: sensor em formato de circuito integrado, usado para monitorar a qualidade do ar por detecção de compostos orgânicos voláteis e CO_2 , com alimentação de 3,3 Vdc e saída através de comunicação com o SPI - Interface Periférica de protocolo Serial, investimento de aproximadamente R\$ 150,00 (cento e cinquenta reais);
- Li-820: sensor infravermelho de alto desempenho para análise de CO_2 , fonte de alimentação de 12 a 30 Vdc, corrente de 4 a 20 mA e saídas de tensão de 5 Vdc, possibilidade de calibração zero e curva de calibração, investimento de aproximadamente R\$ 70.000,00 (setenta mil reais).

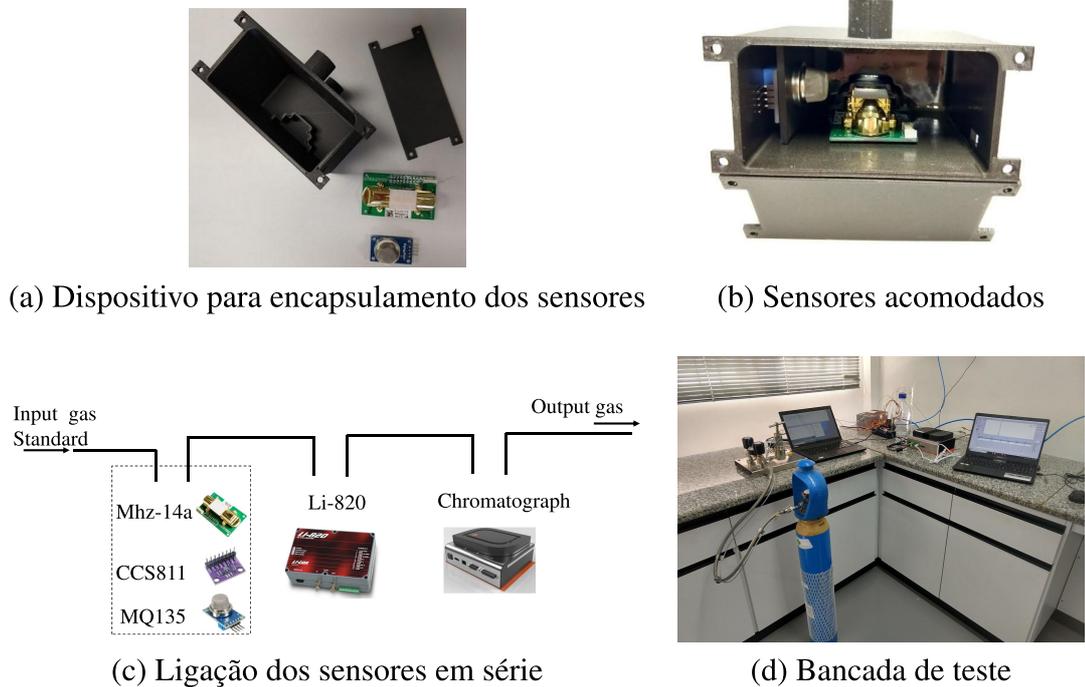
Como os sensores Mh-z14a, CSS811 e o MQ 135 são abertos, foi necessário um encapsulamento para que fosse possível realizar a leitura dos valores de CO_2 dentro de um sistema fechado. Para isso foi utilizados técnicas de manufatura aditiva, onde através de uma impressora 3D foi realizada a impressão de uma caixa fechada para acomodação dos sensores. As Figuras 31(a) e 31(b) mostram o encapsulamento dos sensores Mh-z14a, CSS811 e o MQ 135. Tornando possível a utilização desses sensores no protótipo.

Foi realizado a implementação de uma bancada de testes, Figura 31(d), para verificação de funcionamento dos sensores de CO_2 . Os testes foram feitos utilizando uma mistura de gás padrão, adquirida da Air Liquide, o relatório técnico da mistura pode ser observado no anexo A, foram então interligando todos os sensores em série, conforme Figura 31(c), ao mesmo sistema fechado onde foi injetado CO_2 e verificando as suas leituras.

5.1.1.2 Sensor de Umidade de Solo

Os sensores para medição da umidade do solo são importantes para que seja mantido o valor entre 50 % durante a realização de todos os ensaios. Podemos encontrar diversos sensores com princípios de funcionamento diferentes. (ADLA et al., 2020) comparam sensores resistivos e capacitivos de baixo custo e chegam a conclusão que os sensores capacitivos possuem melhor

Figura 31: Sistemática desenvolvida para testes e medição do sensor de CO_2



Fonte: elaborados pelo autor

desempenho quando comparado com os resistivos. Além disso os sensores resistivos possuem partes metálicas que devem ficar em contato com o solo o que ao longo do tempo gera oxidação e problemas de medição. Os autores utilizaram métodos de comparação direta com quatro tipo de solos diferentes e um padrão secundário. Com base nessa comparação foi escolhido o sensor “capacitive soil moisture sensor v1.2”, que pode ser visualizado na Figura 32.

Figura 32: Sensor de umidade do solo



Fonte: adaptado de (ADLA et al., 2020)

Para validar os sensores capacitivos tomou-se como referencia a norma ASTM D2216 (D2216-19, 2019) que descreve métodos de análise de umidade em solo, foi utilizado um equipamento comercial da marca Sartorius modelo Mark 3 Moisture Analyzer como padrão para calibração dos sensores.

5.1.1.3 Medição de Fluxo de Ar

Para que seja possível a determinação da evolução de CO_2 com a utilização de sensores, é necessário a medição do fluxo de ar na entrada do sensor em questão. Como a determinação do percentual de biodegradabilidade é feito utilizando a massa de CO_2 gerado pelos microrganismos presentes no composto de teste, é realizado um cálculo tomando como base a equação 5.1 descrito para conversão dos valores de CO_2 em ppm para gramas.

$$CO_2(g) = \frac{F \cdot CO_2(ppm) \cdot t \cdot M(CO_2)}{V \cdot 10^6} \quad (5.1)$$

$$V = R \cdot \frac{T}{P} \quad (5.2)$$

Onde:

F: fluxo de ar (m^3/min)

CO_2 : medição de CO_2 (ppm)

t: tempo de amostragem de CO_2 (segundos)

M: massa molar de CO_2 (44,01g)

R: constante ideal dos gases ($8,314472 m^3 \cdot Pa/min \cdot K$)

T: temperatura do gás medido (K)

P: pressão do gás medido (Pa)

10^6 : fator de conversão para ppm

Foi utilizado um sensor de fluxo de massa modelo GFC da marca Aalborg Figura 33, esse sensor possui uma saída de tensão (0 à 5V) o que possibilita a medição do fluxo de ar, através da variação de tensão da saída do sensor, assim é possível a conexão do sensor junto a sistemas de controle e monitoramento, os valores de fluxo dos reatores são lidos um por vez e caso alguns deles esteja fora do necessário, é emitido um alarme para que o operador faça novamente o ajuste.

Figura 33: Sensor de fluxo de ar



Fonte: adaptado de Aalborg

Após pesquisas sobre as normas de referência para ensaios de biodegradabilidade de

materiais poliméricos, não foi encontrado um valor de referência para o fluxo de ar a ser utilizado. Os trabalhos similares pesquisados, descrevem que esse fluxo não pode ser muito alto a ponto de secar as amostras, como também não muito baixo, deixando os microorganismos com falta de ar. Sendo assim, (CASTELLANI et al., 2016) usou em seu protótipo um fluxo de 20L/h, aproximadamente 333 mL/min, (FUNABASHI; NINOMIYA; KUNIOKA, 2009) usou uma vazão de 10 mL/min, (HOSHINO et al., 2007) descreve em seu artigo a utilização de um fluxo de ar entre 10 e 30 mL/min. Com base nos trabalhos relatados e após alguns testes preliminares no protótipo desenvolvido, foi selecionado um fluxo de ar a ser utilizado, o qual será ajustado através de válvulas de fluxo em valores de 300 mL/min.

Como um dos objetivos dessa dissertação é a implementação de um protótipo de baixo custo, ficaria inviável a instalação de rotâmetro ou medidores de fluxo em todos os dezoito reatores de teste. Então foi definido um procedimento de regulagem de fluxo que pode ser feito a qualquer momento (antes ou durante os ensaios). O operador irá apertar uma chave instalada que passa por diferentes telas do display do equipamento, nesse momento o display irá informar o fluxo dos reatores de teste, cada vez que a chave é pressionada é medido um reator diferente, permitindo a instalação de um único medidor de fluxo e reguladores de baixo custo para regulagem. Ao final da regulagem de todos os fluxos é então necessário pressionar o botão de confirmação.

5.1.2 Reatores e Câmara de Aquecimento

Chama-se de reatores os frascos onde serão depositados os materiais de teste, conforme as normas de referência para implementação desses ensaios, os reatores devem possuir uma entrada de ar e uma saída e volume entre 2 L e 5 L. Foi então projetado 34(c) e construído 34(d) um reator em vidro com tampa com rosca, esse tipo de tampa facilita a troca de amostras no início e final de cada teste, foi projetado também uma terceira entrada, pois com a circulação de ar é natural que o composto de teste perca umidade, essa entrada será então utilizada para adicionar água de forma automática realizando o controle de umidade dos testes, que deve ser mantida em valores próximos a 50 %.

Conforme as definições das normas de referência para realização dos testes de biodegradabilidade de materiais poliméricos é necessário que as amostras e composto de teste, estejam a temperatura de 58 °C devendo ser mantidas a essa temperatura com variações máximas de ± 2 °C durante todo o ensaio.

Para isso foi adquirido uma estufa com circulação forçada de ar, com dimensões de 1000 x 950 x 650 mm, possibilitando a colocação de até 18 reatores de 2 L para realização dos ensaios. Nas Figuras 34(a) e 34(b) é possível observar o projeto da câmara de aquecimento com a distribuição dos reatores de teste e a câmara produzida para acondicionamento dos reatores de teste. O sensor de temperatura que faz o controle da temperatura interna é do tipo pt100, o sensor está interligado a um controlador de Novus N120 que faz o controle de um relé de estado

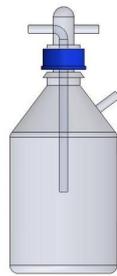
Figura 34: Reatores e câmara de aquecimento projetados e construídos



(a) Projeto para câmara de aquecimento



(b) Câmara produzida



(c) Projeto do reator de teste



(d) Reator produzido

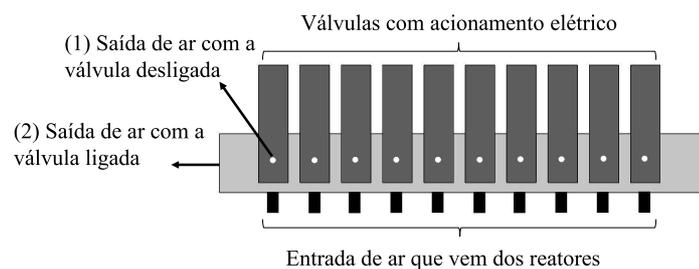
Fonte: adaptados pelo autor

sólido para acionamento das resistências, através de um controle PID – Proporcional Integral Derivativo, permitindo um controle de temperatura preciso.

5.1.3 Válvulas

Conforme visto nos itens acima serão utilizados de apenas um sensor de CO_2 e um sensor de fluxo, é necessário fazer o chaveamento para leitura de um reator por vez, para isso será instalado um conjunto de válvulas interligadas a um bloco metálico, esse conjunto é chamado de Bloco Manifold.

Figura 35: Esquema explicativo de um bloco manifold



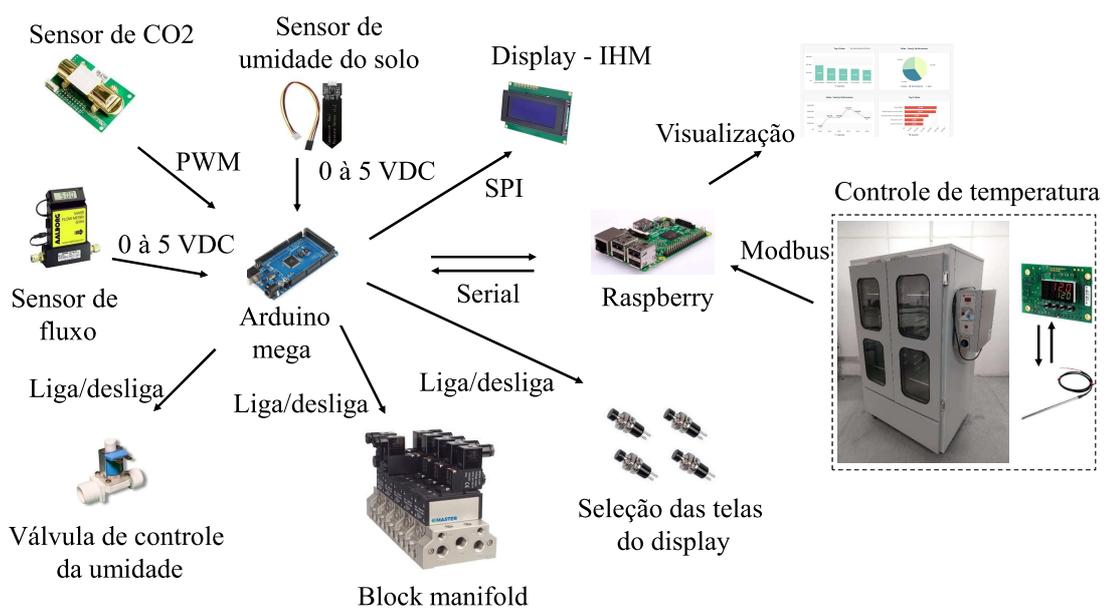
Fonte: elaborado pelo autor

Serão utilizados dois blocos, os quais possuem 10 entradas de ar, essas entradas vêm de cada um dos reatores, quando uma eletroválvula é acionada o ar é direcionado da saída 1 para a saída 2 direcionando o ar com CO_2 de cada um dos reatores até o sensor de análise de CO_2 . Para evitar contaminação entre um reator e outro, é feita uma purga entre as leituras, após 25 minutos de purga o sensor tem seu ponto zero calibrado e as leituras são feitas após 25 minutos de estabilização, esses tempos foram levantados com base nos testes do sensor demonstrado no item 4.1.1, ou seja, os tempos de leitura entre um reator e outro são de 50 minutos.

5.1.4 Integração entre sensores

Todos os sensores mencionados serão conectados conforme demonstrado na Figura 36. Cada dispositivo que compõe o protótipo possui um determinado tipo de comunicação: as medições de temperatura são enviadas via RS 485 por protocolo Modbus, o fluxo registrado por cada reator é enviado via saída analógica de corrente de 4 à 20mA, as emissões de CO_2 , são enviadas por pulsos de sinais PWM, o display que serve como auxílio na disponibilização das informações comunica com protocolo SPI, os sensores de umidade via sinal analógico de tensão de 0 à 5 VDC, as válvulas dos manifolds, entrada de água e chaves de pulso, são conectadas de forma digital sendo nível lógico alto (5 VDC) ou baixo (0 VDC), ou seja, apenas on/off, a comunicação entre as placas se dá por comunicação serial, por fim o envio das informações de ensaios é feita através do protocolo MQTT - Message Queuing Telemetry Transport (Transporte de Telemetria do Serviço de Enfileiramento de Mensagens).

Figura 36: Representação da integração entre os sensores e as placas de processamento - A direção das setas representam as saídas e entradas das placas de processamento

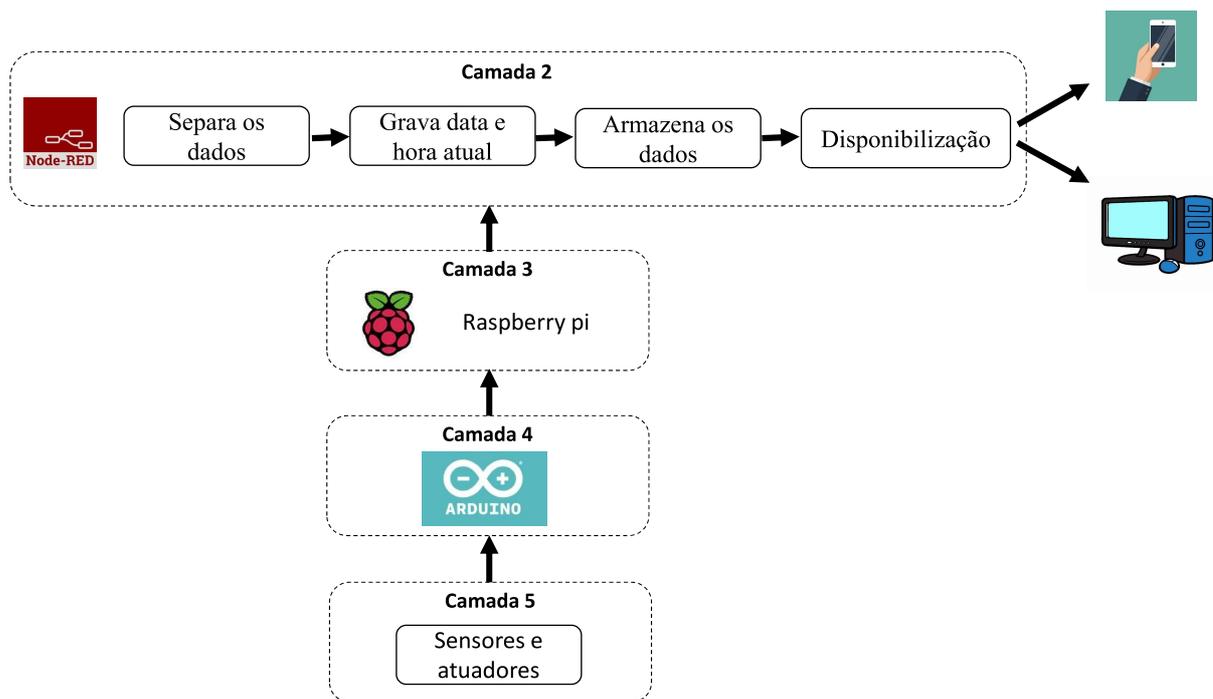


Fonte: elaborado pelo autor

Serão utilizados dois dispositivos de processamento no desenvolvimento do protótipo para

avaliação do modelo IoTBio. O primeiro dispositivos trata-se de um microprocessador ATmega2560 embarcado em Arduíno, este, irá realizar o controle de acionamento dos atuadores e recebimento dos sinais de todos os sensores. Os dados coletados dos sensores, serão transmitidos através do Arduíno para uma placa Raspberry pi 3 modelo B embarcado com Linux, a qual irá armazenar todas as informações e disponibiliza-las para os usuários através de um sistema supervisorio, servindo como um banco de dados. Os dados coletados e armazenados pela Raspberry serão utilizados para implementação de um sistema de predição de resultados. Optou-se pela utilização da placa Arduíno, por se tratar de uma placa de prototipagem rápida com interfase programada em linguagem C, facilitando a manipulação dos dispositivos que irão compor o protótipo. E a placa Raspberry pela facilidade na utilização de acesso via internet e memória de armazenamento. A arquitetura detalhada proposta para implementação do módulo IoT é mostrada na Figura 37.

Figura 37: Arquitetura geral do módulo de IoT proposto para implementação e avaliação do modelo IoTBio, seguindo o modelo de camadas para sistemas IoT



Fonte: elaborado pelo autor

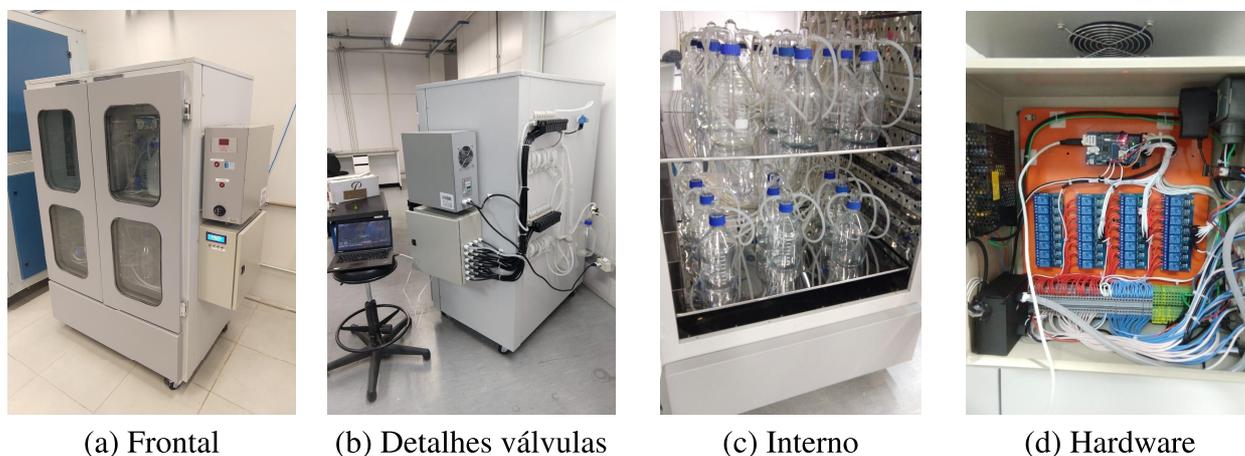
Serão utilizados sensores e atuadores (camada 5 de um sistema IoT), uma placa de recebimento dos dados (camada 4), uma placa para processamento e armazenamento das informações recebidas (camada 3) e um sistema supervisorio para visualização dos dados de ensaio (camada 2). Pode-se perceber que essa proposta vai trabalhar até a camada 2 de uma arquitetura IoT, uma vez que não é aplicado nenhum software para monitoramento de outras informações de processo, como matéria prima e ordem de serviço, logo não existe a camada 1 no modelo proposto.

A placa Arduíno será programada em linguagem C. Já a placa Raspberry será programada

tomando como base a plataforma Node-red, que trata-se de um programa baseado em fluxo, nele são utilizados fluxos visuais. O node-red funciona com acesso via internet através do IP da Raspberry, porém esse acesso só é permitido por dispositivos que estejam conectados a mesma rede local. É possível fazer um acesso por dispositivos em outras redes, nesse caso é necessário a utilização de um servidor externo, como por exemplo do Bluemix da IBM. Acredita-se que nesse caso os dados devem ser preservados de ameaças externas, então deverá ser utilizado apenas por pessoas que tiverem acesso a rede local.

Com base nos tópicos descritos, foi elaborado um protótipo para teste e avaliação do módulo de IoT. Esse protótipo foi crucial para verificar o desempenho e possibilitar a montagem final de um equipamento automatizado para teste da biodegradabilidade de materiais poliméricos.

Figura 38: Protótipo desenvolvido para avaliação do IoTBIO



Fonte: elaborados pelo autor

Na Figura 38 (a) mostra a frente do protótipo desenvolvido. Na Figura 38(b) é possível visualizar os detalhes da montagem das válvulas. A Figura 38(c) apresenta detalhes da distribuição dos vasos de teste. E por fim na Figura 38(d) mostra o painel elétrico com o hardware desenvolvido onde foram acomodados as placas Arduino, Raspberry, os relés de acionamento e o sensor de CO_2 .

5.1.5 Tolerância a falhas

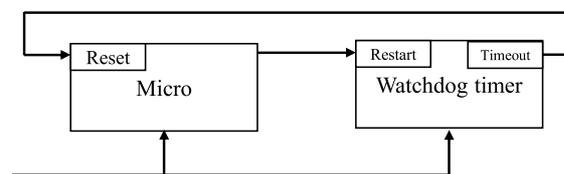
O protótipo é composto por uma única placa Arduino e Raspberry tornando o sistema centralizado. Com o intuito de tornar o sistema mais robusto e tolerante a falhas foram implementadas algumas técnicas:

- Watchdog: esse algoritmo tem como finalidade implementar um timer que é executado em paralelo com o programa principal do microcontrolador. O algoritmo é capaz de verificar na eventualidade do programa não ser executado em sua totalidade, ou seja, se o programa "travar" por algum motivo. Se verificado esse tipo de anormalidade o algoritmo

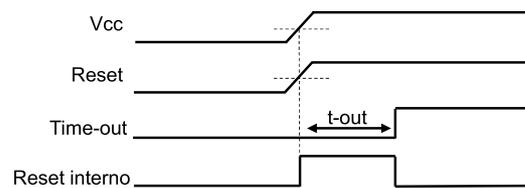
realiza um reset do microcontrolador. É importante ressaltar que o Watchdog só deve entrar em operação se alguma anomalia for detectada, não é usual sua atuação demasiada. A Figura 39(a) ilustra o funcionamento do algoritmo;

- **Brown out detection (BOD):** trata-se de um hardware interno ou externo que detecta problemas na alimentação de um sistema. No caso da placa Arduino esse artifício pode ser utilizado para monitorar quedas de tensão indevida e se necessário realizar uma reinicialização da placa, garantindo assim o seu funcionamento. A Figura 39(b) ilustra o funcionamento do BOD;
- **Nível de sensor:** sensores podem se danificar ao longo do tempo. Dessa forma foi realizado uma programação para verificar os níveis indesejados dos sensores do protótipo, caso os níveis de medição sejam máximos ou mínimos, o microcontrolador tem a capacidade de colocar o valor do sensor danificado em zero e interromper o funcionamento e mostrar uma mensagem ao operador. A Figura 39(c) ilustra o funcionamento do sistema de verificação de nível dos sensores;

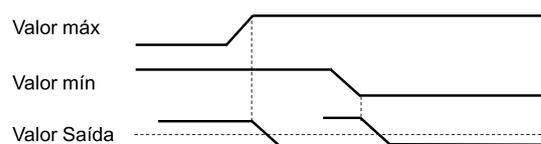
Figura 39: Sistemas de tolerâncias a falhas



(a) Watchdog



(b) Brown out detection (BOD)



(c) Nível de sensor reatores

Fonte: elaborados pelo autor

5.1.6 Configuração de teste do protótipo, avaliação do módulo de IoT

Emadian, Onay e Demirel (2017) realizaram estudos sobre a biodegradabilidade de materiais poliméricos em ambientes naturais, como solo e mar. Foram explorados pelos autores diversos materiais com diversas condições de temperatura, umidade, pH e oxigênio. Os autores chegam a conclusão que todas essas variáveis influenciam na degradação natural de polímeros. Além disso é demonstrado pelos autores que a umidade do solo e a temperatura influenciam significativamente na biodegradabilidade (EMADIAN; ONAY; DEMIREL, 2017). Borowik e Wyszowska (2016) fazem um estudo com diferentes percentuais de umidade do solo. Em seu artigo os autores mostram que micro organismos diferentes tem afinidade por um determinado percentual de umidade do solo. Para o desenvolvimento de bactérias organotróficas foi maior para o nível de 20 % de umidade, para actinomicetos, o nível de umidade do solo de 40 % foi o mais adequado e fungos se desenvolveram melhor no nível de umidade do solo de 60 % (BOROWIK; WYSZKOWSKA, 2016). Dessa forma, podemos entender que é necessário um controle da umidade do solo para os testes de biodegradabilidade.

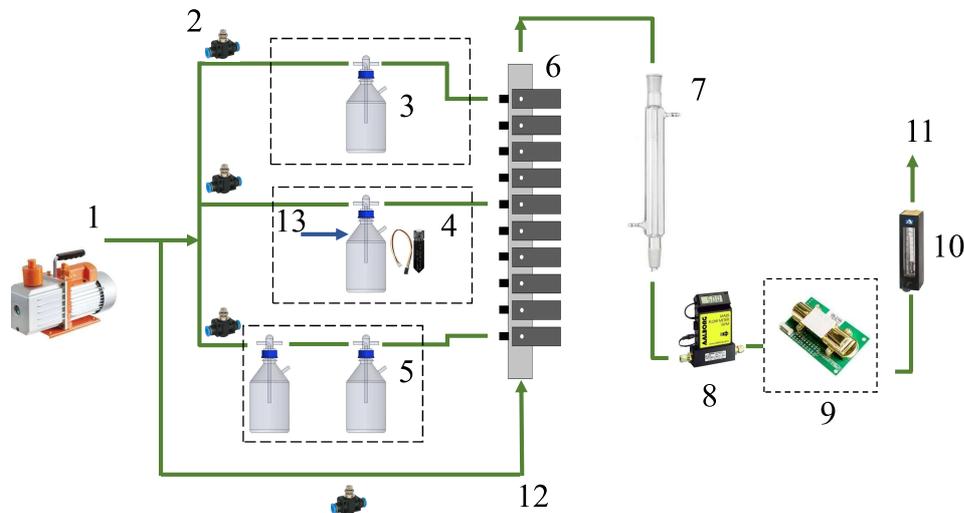
Uma vez que as pesquisas realizadas sobre esse assunto, não abordavam uma metodologia automática de controle da umidade do solo, decidiu-se verificar a efetividade do método utilizado por outros pesquisadores e o método apresentado pela ISO 14855-1, o qual propõe um controle de umidade do solo através da passagem da ar por um frasco com água, como forma de umidificação do ar, Figura 23.

Dessa forma, foram desenvolvidos três cenários de testes distintos, conforme Figura 40, os mesmos possuem diferentes formas de controle de umidade do solo. Esses cenários vão determinar a importância ou não da realização de um controle preciso sobre a umidade no composto de teste. O protótipo foi montado quase que em sua forma final, sendo utilizado nesse primeiro momento para realização da avaliação do módulo de IoT, os resultados extraídos desse protótipo serão utilizados na decisão da forma de controle de umidade final a ser utilizada.

Os três primeiros reatores não possuirão nenhum tipo de controle de umidade (3), os próximos três (4) vão possuir uma entrada de água (13) automática controlada por uma eletroválvula e sensores de umidade do solo, os últimos reatores (5) irão utilizar a metodologia de teste adotada por alguns artigos e pelas normas de referência, onde existe um frasco com água antes dos reatores de teste, com a finalidade de realizar a umidificação do ar que entra nos reatores, levando essa umidade até o composto de solo.

Além dos reatores existe um sistema de injeção de ar (1), válvulas de controle de fluxo manual (2) que devem ser ajustadas no início do processo onde é possível verificar o fluxo de ar de cada reator no rotâmetro (10) através de uma chave de seleção é possível passar por cada um dos reatores para que seja possível fazer esse ajuste prévio. Em seguida o ar passar pelo bloco manifold (6) onde o ar de cada um dos reatores é direcionado ao medidor de CO_2 (9), a leitura de CO_2 é feita após 20 minutos de estabilização e entre as leituras é passado ar limpo (12)

Figura 40: Metodologia de teste para definição do controle de umidade do solo para teste de biodegradabilidade



Fonte: elaborado pelo autor

para que o sistema não tenha contaminação entre as leituras de cada reator, na saída do bloco manifold existe uma coluna condensadora de água (7) que serve para remoção da umidade do ar, em seguida passa pelo medidor de fluxo de massa (8) entrando no sensor de CO_2 (9) para realizar as medições.

5.1.6.1 Calibração de Sensores

Quando trabalhamos com medições de uma quantidade é necessários a definição de um intervalo o qual podem ocorrer variações em torno do melhor valor estimado. Esse parâmetro depende de diversos parâmetros como condições ambientais, habilidade do operador, resolução do instrumento, entre outros. (BALBINOT; BRUSAMARELLO, 2019) Essa variação é determinada como incerteza de medição a qual é representada pela Equação 5.3:

$$V_m \pm \Delta V_m \quad (5.3)$$

No qual:

V_m : Melhor estimativa do valor medido;

ΔV_m : Faixa de variação, onde o valor medido pode oscilar.

O Instituto Nacional de Metrologia, Qualidade e Tecnologia - INMETRO faz referência ao método ISO GUM 95 para determinação das incertezas de medição. Segundo (INMETRO, 2008) é possível resumir a metodologia do ISO GUM 95 em:

- Definição do mensurando: os mensurados as medições dos valores de temperatura, umidade solo, fluxo do ar e CO_2 ;

- **Elaboração do diagrama causa–efeito:** trata-se de um diagrama para auxiliar na verificação dos fatores que podem influenciar na medição dos mensurados. No caso da calibração dos sensores aplicados nessa dissertação existem três fontes que interferem nos valores medidos: medições do sensor, resolução dos padrões e calibração dos padrões utilizados;
- **Estimativas das incertezas das fontes de entrada:** as incertezas de medição das fontes de entrada são definidas de acordo com a distribuição dos dados. Chamamos de avaliação tipo A os dados intrínseco ao processo de medição e é realizada através de um tratamento estatístico do conjunto de repetições das observações. Nas avaliações do tipo A, os dados representam uma distribuição estatística normal. A Equação 5.4 mostra como realizar o cálculo de avaliações tipo A. As avaliações do tipo B é efetuada por outros meios que não a análise estatística de uma série de observações como por exemplo a avaliação de medições anteriores. A Equação 5.5 mostra como realizar o cálculo de avaliações tipo B para instrumentos digitais;

$$u(x_i) = \frac{s(x_i)}{\sqrt{n}} \quad (5.4)$$

$$u(x_i) = \frac{a}{2\sqrt{3}} \quad (5.5)$$

No qual:

$u(x_i)$: incerteza calculada;

$s(x_i)$: Desvio padrão das amostras/leituras do sensor em análise;

n : número de repetições para $n > 10$;

a : intervalo simétrico de uma distribuição retangular;

- **Cálculo dos coeficientes de sensibilidade:** trata-se do coeficientes de sensibilidade do mensurando em relação a cada fonte de entrada. Como a calibração dos sensores foi feita com base em processo de comparação direta, não se faz necessário o uso de cálculo dos coeficientes de sensibilidade;
- **Combinação das componentes:** quando não existem correlação entre as incertezas das fontes de uma medição, é possível fazer o cálculo de uma incerteza combinada a qual é dada pela Equação 5.6;

$$u_c = \sqrt{u_1 + u_2 + u_3 + \dots + u_n} \quad (5.6)$$

- **Cálculo dos graus de liberdade efetivos:** a equação de Welch-Satterthwaite 5.7 é utilizada para realizar o cálculo dos graus de liberdade efetivos da incerteza-padrão combinada;

$$V_{eff} = \frac{u_c^4(y)}{\sum_{i=0}^n \left(\frac{u_i^4}{v_i}\right)} \quad (5.7)$$

No qual:

u_c : incerteza combinada calculada;

u_i : incerteza-padrão de cada fonte de entrada na unidade do mensurando;

v_i : graus de liberdade de cada fonte de entrada;

- Determinação do fator de abrangência (K): determinado com base na tabela t de Student anexa em essa dissertação;
- Estimativa da incerteza expandida: trata-se da incerteza final da medida do sensor, determinada pela Equação 5.8;

$$U = K u_c \quad (5.8)$$

Os sensores utilizados para o protótipo do hardware desenvolvido foram calibrados e as planilhas desenvolvidas para essas calibrações estão anexadas ao final do trabalho.

5.1.7 Visualização dos dados

A visualização dos dados de ensaio foram feitas através do Node-red, implementado na placa Raspberry. Esse programa possui interfase de programação baseada em fluxos visuais. A utilização do Node-red permite o acompanhamento dos testes em tempo real através do acesso a página web com os dashboards das medições do protótipo. A implementação do Node-red permitiu a visualização dos dados em qualquer dispositivo que esteja conectado a mesma rede local da Raspberry.

Com o hardware, o software para visualização dos dados do módulo de IoT desenvolvido e a metodologia de teste definida, serão descritos no próximo capítulo as definições para implementação do Módulo de Aprendizado de Máquina.

5.2 Implementação do Módulo de Aprendizado de Máquina

Aqui serão descritos os passos para implementação do módulo de Aprendizado de Máquina, que será utilizado para previsão dos resultados do percentual de biodegradabilidade proposto pelo modelo IoTBio.

Para implementação dos algoritmos de Aprendizado de Máquina, foi necessário realizar um levantamento de dados de ensaios da determinação do percentual de biodegradabilidade já realizados. Antes do desenvolvimento de um protótipo automatizado, proposto por essa dissertação, o Instituto Senai de Inovação em Engenharia de Polímeros já realizava esses

ensaios, porém com equipamentos não automatizados. Dessa forma foi coletado esses dados e chegou-se a um montante de trinta e três amostras (33) de ensaios concluídos, ou seja 33 polímeros. Após a implementação do equipamento proposto por essa dissertação conseguiu-se atingir trinta e cinco (35) polímeros já ensaiados.

Sendo assim, as entradas do módulo de Aprendizado de Máquina são os dados referentes ao percentual da biodegradabilidade de ensaios de biodegradabilidade de materiais poliméricos, percentual esse determinado através das medições do CO_2 emitido pelos micro organismos presentes na amostra em teste. As medidas de CO_2 são feitas uma por vez, tendo um intervalo de medição de 40 minutos, sendo 20 minutos utilizados para purga/limpeza do sistema e 20 minutos para estabilização do sensor. Esses dados são analisados durante todo o tempo de ensaio, que varia de 90 à 180 dias e são acumulados ao longo de todo esse tempo para realização do cálculo percentual de biodegradabilidade.

Como saídas do modelo, deseja-se que os algoritmos tenham a capacidade de realizar previsões do percentual de biodegradabilidade das amostras em teste, antes do período completo de teste, ou seja, se um teste possui 90 dias de ensaio, o algoritmo deve prever quando e quanto de biodegradabilidade esse polímero irá atingir, sem a necessidade de decorrer todos os dias de teste. Reduzindo dessa forma o tempo de teste e conseqüentemente os custos da realização dos mesmos.

5.2.1 Pré-processamento dos dados

O módulo de pré-processamento trata-se de um dos mais importantes para que obtenha bons resultados no trabalho com Aprendizado de Máquina. Aqui é necessário um tratamento dos dados para que seja possível a realização das previsões. Primeiramente todas as amostras devem ser normalizadas em termos de amplitude (eixo y), ou seja, os valores de medição de CO_2 devem ser colocados entre zero "0" para 0 % de biodegradabilidade e um "1" para 100 % de biodegradabilidade. Em seguida os dados devem possuir uma duração igual em termos de dias (eixo x). Nesse caso para dados menores que o valor máximo de dias (130) será repetido o valor máximo de medição de CO_2 desde o último dia de ensaio até o dia 130, ou seja, se uma amostra possuiu 50 % de biodegradabilidade (valor de 0,5) no dia 90, será extrapolado a medição de 0,5 até o dia 130. Na Figura 41 é possível perceber um exemplo de extrapolação para o polímero 01, onde o ensaio seria encerrado no dia 90 devido a sua estabilização, porém para normalização do eixo de dias (eixo x), foi mantido o mesmo valor até o dia 130.

Para realizar manipulações de dados em algoritmos computacionais é necessário que os dados sigam padrões internacionais. Nesse caso é necessário a troca de operador decimal. Os padrões brasileiros acabam utilizando virgula ",", porém para utilização dos dados em Python é necessário que os dados estejam com ponto "." para os dados de análise. Na Figura 41 é possível perceber que os dados já receberam a troca do operador decimal para possibilitar a utilização das bibliotecas e algoritmos em Python. Outro procedimento realizado na etapa de

pré-processamento é a padronização das casas decimais dos valores, nessa etapa todos os valores devem possuir a mesma quantidade de números após o separador decimal.

Figura 41: Exemplo de pré-processamento e entradas de dados

Dias	0	1	2	3	...	89	90	91	92	...	127	128	129	130	
Polímero 01	0	0.1	0.2	0.3	...	0.5	0.5	0.5	0.5	...	0.5	0.5	0.5	0.5	← Amostra extrapolada para 130 dias
⋮															
Polímero 20	0	0.05	0.2	0.21	...	0.32	0.33	0.34	0.38	...	0.6	0.65	0.65	0.65	
⋮															
Polímero n	0	0.2	0.25	0.3	...	0.5	0.6	0.7	0.8	...	0.98	0.99	0.98	0.99	↑ Separador decimal

Fonte: elaborado pelo autor

Conforme descrito no capítulo de referencial teórico das séries temporais, trata-se de um conjunto de dados obtidos ao longo do tempo. No caso dessa dissertação são obtidos valores de percentual de biodegradabilidade ao longo do tempo. Dessa forma os algoritmos de Aprendizado de Máquina, os quais trabalham com séries temporais, precisam que as sequências de dados sejam ininterruptas. Os dados posteriores a essa dissertação não eram adquiridos em períodos fixos e nem aos finais de semana. Esses valores "brancos" devem ser preenchidos. Uma das formas de preenchimento desses valores pode ser através da técnica de interpolação linear (HARRINGTON, 2012). O método de interpolação linear busca valores intermediários entre outros dois valores através de uma linha entre os dois pontos, conforme pode ser observado na Equação 5.9. Assim, como os valores percentuais de biodegradabilidade crescem ao longo do tempo, a técnica de interpolação é adequada para preenchimentos dos valores faltantes.

$$y = y_0 + (y_1 - y_0) \frac{x - x_0}{x_1 - x_0} \quad (5.9)$$

No qual:

x : valor desejado de x ;

y : valor desejado de y ;

y_0 : valor inicial de y ;

y_1 : valor final de y ;

x_0 : valor inicial de x ;

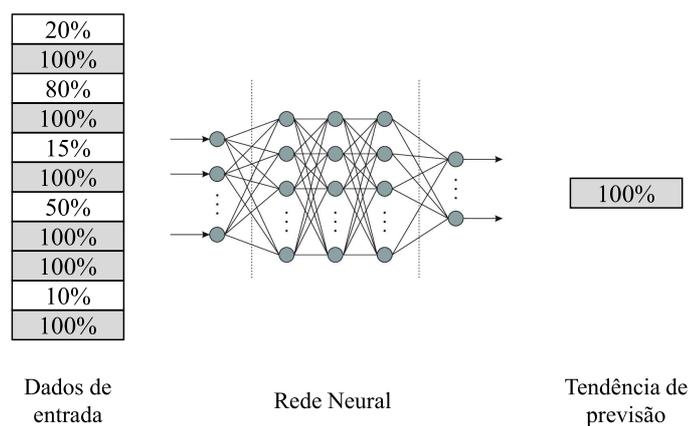
x_1 : valor final de x ;

Ainda no módulo de pré-processamento é necessário a verificação da qualidade dos dados disponíveis. Dados não concisos podem influenciar negativamente os resultados dos algoritmos de Aprendizado de Máquina. Para verificação desses dados, foi utilizado o teste de correlação. O teste de correlação trata-se de um teste estatístico realizado entre duas amostras, as quais deseja-se verificar qualquer tipo de correlação ou dependência através de relações

entre classes estatísticas (WASSERMAN, 2013). Porém, os testes de correlação são realizados para comparação entre duas variáveis. Para resolver esse problema foi utilizado um algoritmo que tem como finalidade realizar a correlação entre todos os dados, formando nesse caso uma matriz de correlação, onde todos polímeros são testados entre si. Após a realização desse teste é possível analisar os dados e verificar quais polímeros são considerados como outliers e excluí-los do bando de dados.

Após a exclusão de outliers é necessário verificar a distribuição de frequência estatística dos dados disponíveis. Conforme visto no capítulo de fundamentação teórica as Redes Neurais Artificiais possuem funcionamento similar ao cérebro humano. Diante disso é necessário a verificação das quantidades de dados em cada percentual máximo de biodegradabilidade. A utilização de dados com resultados desequilibrados, fazem com que a rede apresente resultados tendenciosos, ou seja, os dados utilizados nessas proposta de dissertação, tratam-se de séries temporais que descrevem o percentual de biodegradabilidade de polímeros ao longo do tempo. Os percentuais podem variar entre zero por cento "0%" e cem por cento "100%". Se forem utilizados muitos dados que chegam a cem por cento e poucos que chegam nos demais valores, a rede tende a prever que todos os dados devem ser de 100%. Essa tendência equivocada de resultados é chamada de Overtraining (AMARI, 1967), o qual pode ser traduzido como sobre-treinamento. Isso quer dizer que no caso de uma rede ser treinada excessivamente com um tipo de dados, a mesma tende a prever esses valores equivocadamente.

Figura 42: Exemplo de Overtraining, os dados de entrada de uma Rede Neural possuem valores em excesso com um único resultado (100%), deixando a entrada de dados desbalanceada, fazendo com que a rede tenha valores tendenciosos na sua previsão



Fonte: elaborado pelo autor

Com os dados pré-processados, julga-se que agora os mesmos estão prontos para aplicação dos algoritmos de Aprendizado de Máquina propriamente ditos, destinados a previsão de valores futuros.

5.2.2 Algoritmos de Aprendizado de Máquina - Predição

Durante as pesquisas realizadas, não foi localizado nenhum estudo que tenha aplicado técnicas de aprendizado de máquina em ensaios de biodegradabilidade de materiais poliméricos. Desta forma foi necessária verificar por técnicas mais aplicadas a séries temporais, devido a característica dos dados desses ensaios. Com base nos estudos feitos foi possível perceber que o uso de técnicas de AM possibilitam a construção de modelos preditivos automatizados. Essas previsões geram valores que servirão na tomada de decisões e ações inteligentes em tempo real. No caso dessa dissertação a implementação de um algoritmo de AM servirá para redução dos tempos de teste da biodegradabilidade de materiais poliméricos, uma vez que esses testes podem demorar até 180 dias em sua execução.

Autores como (KE et al., 2018), (BAHDANAU; CHO; BENGIO, 2014) e (SUTSKEVER; VINYALS; LE, 2014) estudaram e comprovaram o poder das Redes Neuras Recorrentes do tipo Long Short Term Memory - LSTM. As LSTM foram introduzidas por (HOCHREITER; SCHMIDHUBER, 1997). Diferente das RNN comuns as LSTM podem armazenar informações a longo prazo, fazendo com que seja possível "memorizar" padrões de dados passados. As LSTM podem selecionar os dados os quais estão passando por sua estrutura. A seleção desses dados é feita através de estruturas chamadas de portões. Esse portões possuem equações de ativação as quais são responsáveis por decidir quais informações "passam" ou "não passam". Sendo assim, a utilização das redes do tipo LSTM vem sendo utilizadas cada vez mais em sistemas de previsão de séries temporais.

Os trabalhos relacionados citados nessa dissertação, apontam como o estado da arte para previsões de séries temporais algoritmos de ARIMA e Redes Neurais, não especificando qual tipo de arquitetura de Rede Neural mais adequada. Diante disso, a seguir serão detalhadas as metodologia aplicada aos algoritmos de ARIMA e RNA para previsão de resultados do percentual de biodegradabilidade.

O método de ARIMA trata-se de um dos modelos mais utilizados para previsão de séries temporais, os mesmos funcionam através do princípio de médias móveis (BOX et al., 2015). (RIGHI et al., 2015) utilizaram o método de ARIMA para previsão de cargas de aplicações em nuvens. Os autores testaram os algoritmos para dados crescentes, decrescentes e oscilatórios.

Outra técnica muito utilizada para previsão de dados temporais é a de Redes Neurais Artificiais, as mais adequadas para se trabalhar com dados sequenciais são as Redes Recorrentes - RNN. Essas redes são extremamente poderosas para implementações de sistemas os quais possuem dados sequenciais não lineares. Quando comparado a uma rede multicamadas, os pesos em um RNN são compartilhados em diferentes instâncias dos neurônios artificiais, cada um associado a diferentes passos de tempo (GOODFELLOW; BENGIO; COURVILLE, 2016). As RNN são características por utilizarem atrasos temporais em suas execuções uma vez que seja possível verificar comportamentos passados, previsões de valores futuros são mais assertivos. (LANG, 1988). Esses atrasos são definidos pelo

programador, no caso dessas dissertação foram testadas diferentes atrasos e verificado qual o melhor se adaptada as series temporais em questão. Porém as RNN não são capazes de obter uma memória grande, foi nesse caso que surgiram as LSTM.

Cardoso et. al. (2020) realizaram implementações de algoritmos de Regressão Linear e RNA para previsão de resultados do percentual de biodegradabilidade através do software Weka (CARDOSO; COSTA; FIGUEIREDO, 2020). O Weka trata-se de uma plataforma aberta, muito utilizada na introdução a técnicas de aprendizado de máquina, pois facilita a implementação rápida de diferentes técnicas para verificar as respostas de acordo com os dados que se possui (Weka - The workbench for machine learning, 2020). Os autores provaram de que é possível realizar previsões para ensaios de biodegradabilidade, porém o Weka trata-se de uma plataforma utilizada somente para avaliação de uma metodologia e prototipagem rápida de diferentes algoritmos dessa forma os algoritmos implementados nessa dissertação serão desenvolvidos em Python.

Algumas bibliotecas de Python foram utilizadas para facilitar as implementações: Pandas, Numpy, Matplotlib, Statsmodels, Sklearn, ARIMA, AutoArima, Seaborn, Keras e Math. Ambas são fundamentais para análise de dados, permitindo diversas manipulações, exportações e importações de diferentes formas, além de facilitarem a aplicação do ARIMA e da RNA LSTM.

5.2.2.1 Algoritmo ARIMA

ARIMA corresponde a uma técnica de previsão de séries temporais, muito utilizadas nos últimos anos. O mesmo possui propriedades estatísticas, sendo possível se trabalhar como autorregressiva pura (AR), média móvel pura (MA) e séries AR e MA combinadas (ARMA), enquanto a parte integral (I) indica que os valores de dados foram substituídos com a diferença entre seus valores e os valores anteriores (ZHANG, 2003).

Os algoritmos de ARIMA não possuem um tipo de treinamento conforme as Redes Neurais Artificiais. Nessa abordagem são calculados parâmetros p (termo auto regressivo), d (diferenças não sazonais para estacionalidade) e q (erros de previsão atrasados pela equação de previsão). Esses parâmetros compõem a equação geral de previsão do algoritmo:

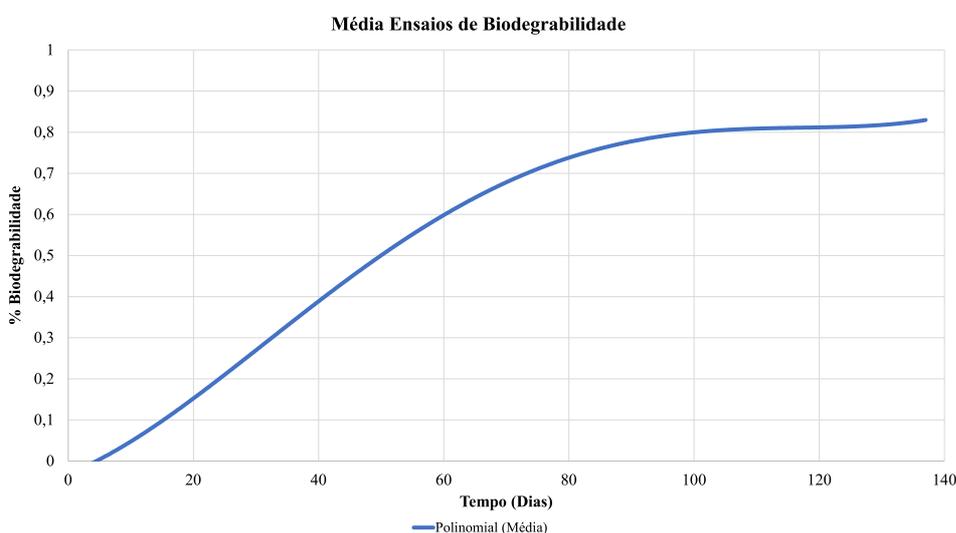
- p : trata-se do termo auto regressivo;
- d : é o valor de diferenças não sazonais necessárias para a estacionariedade;
- q : refere-se a erros de previsão atrasados na equação de previsão.

Com base nesses parâmetros de ARIMA, podemos imaginar que: ARIMA (0,0,0) trata-se de uma média móvel, ARIMA (0,1,0) é considerado um passeio aleatório e ARIMA (0,1,1) pode ser considerado uma suavização exponencial. Além disso séries que possuam

sazonalidades, pode-se aplicar o SARIMA com parâmetros (P,D,Q) para trabalharem na parte sazonal (EHLERS, 2007).

Foi desenvolvido um algoritmo em Python para automatizar a implementação do ARIMA. O sistema computacional tem como objetivo realizar a implementação dos parâmetros de ARIMA (p,d,q) e verificar a acurácia entre valores preditos e reais. Além disso foi utilizado a biblioteca de AutoARIMA, para verificação de quais são os parâmetro mais adequados para o modelo de série temporal dessa dissertação. Sendo assim, para "treinamento" do algoritmo de AutoARIMA foi realizado uma média móvel de todas as séries correspondentes a teste de biodegradabilidade resultantes após o processo de pré-processamento. A Figura 43 mostra a solução para a média móvel desses dados, com base nessa série é que os parâmetros de ARIMA serão definidos.

Figura 43: Dados tomados como base para definição dos parâmetros p, d e q do algoritmo de ARIMA



Fonte: elaborado pelo autor

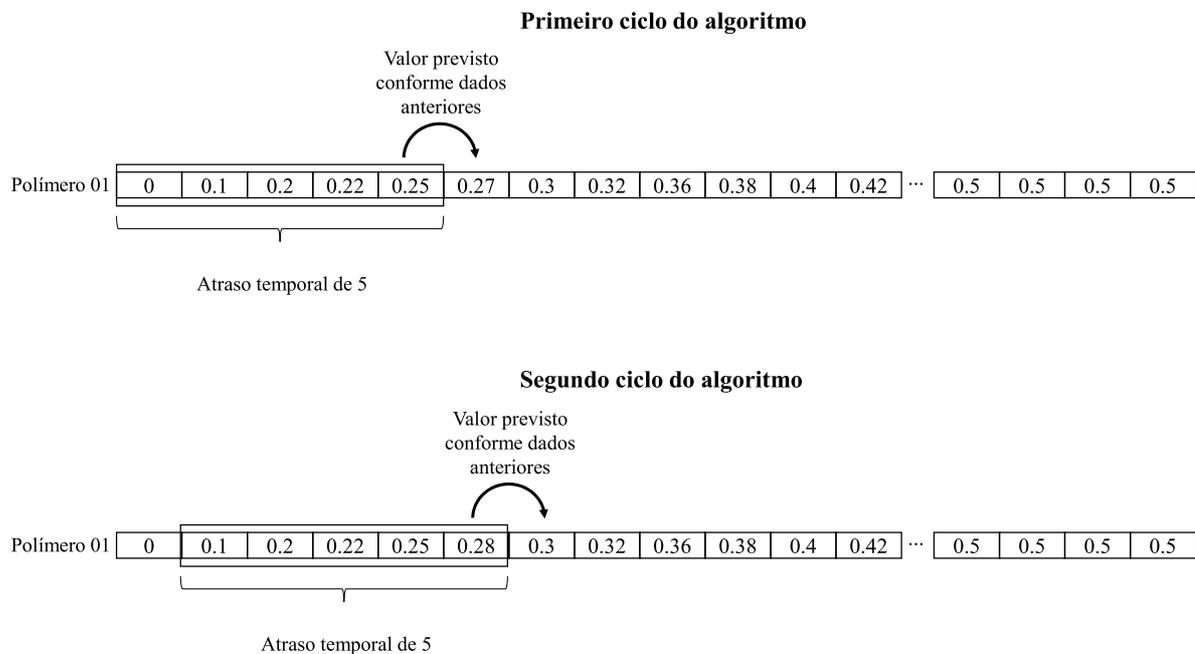
5.2.2.2 Algoritmo RNA com arquitetura LSTM

Os dados pré-processados foram inseridos em uma rede neural artificial do tipo LSTM, os atrasos temporais foram trabalhados com a finalidade de encontrar o atraso que tinha melhores resultados de previsão. Foi desenvolvido uma algoritmo em Python com o objetivo de automatizar o processo de implementação da Rede Neural Artificial Recorrente.

Como tratam-se de dados de uma mesma variável envolvida (CO_2), para determinação do percentual de biodegradabilidade, os dados foram inseridos na rede em série, ou seja, os dados percentuais de cada polímero testado foi inserido um após o outro. Nesse caso, como os dados possuem atrasos temporais, é necessário cuidar para que dados de um polímero não interfira em outro. Por exemplo: para um atraso temporal de 5 dias, a rede analisa 5 medições de CO_2 e prever a próxima, porém ao final de um polímero para outro, não podem ocorrer previsões equivocadas, deve ser utilizados artifícios para que na troca de um polímero para outro, aconteça

a previsão correta, fazendo com que a rede seja treinada corretamente. A Figura 44 faz uma ilustração do funcionamento de uma rede LSTM considerando um atraso temporal de 5 dias, no qual é analisado 5 dias e previsto o próximo, na sequência a janela temporal é deslocada e o algoritmo novamente analisa os 5 últimos valores e prevê o próximo. Assim os pesos da rede são ajustados levando em consideração os valores previstos com base na janela de análise e o valor real previsto.

Figura 44: Esquema de janelamento de uma rede LSTM, considerando um atraso de 5 dias, a rede analisa os 5 últimos valores e prevê o próximo, em seguida verifica a diferença entre valor previsto e real, reajusta os pesos da rede e avança um passo, onde novamente analisa os últimos 5 valores e prevê o próximo, esse loop é realizado até que seja verificado um Overfitting, ou seja, mesmo que reajustados os pesos da rede não existem mais melhoras significativas entre as diferenças dos valores reais e previstos.



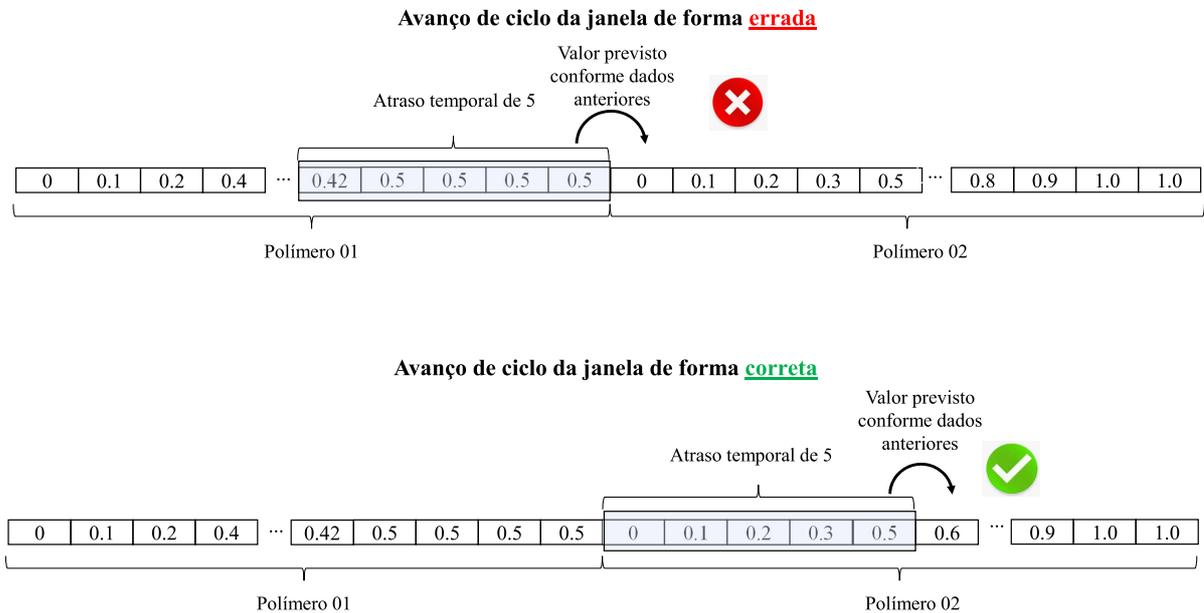
Fonte: elaborado pelo autor

Como deseja-se utilizar o método de janela para verificação das tendências de cada uma das curvas dos polímeros, é necessário tomar cuidado para que no momento em que uma série chegue no final os valores previstos não sejam os de outra, isso que dizer que sempre que for trocado a série de um polímero para outro, o algoritmo deve ser capaz de "saltar" os valores previstos para não sofrer interferências e prever valores equivocados. A Figura 45 mostra como esse problema pode acontecer.

Alguns parâmetros devem ser otimizados para verificação dos melhores resultados da rede implementada, sendo esses: quantidade de neurônios, quantidade de camadas ocultas, quantidade de épocas, função de ativação, largura da janela, batch size e tipo de otimizador.

- Quantidade de neurônios: diz respeito a complexidade da arquitetura de rede neural implementada, quanto maior a quantidade de neurônio maior será a complexidade do

Figura 45: Demonstração de avanço de janela de tempo de forma errada e de forma certa, quando é realizada a troca de um polímero para outro o algoritmo deve realizar um "salto" com toda janela de tempo, para que não aconteça interferência dos dados de um polímeros em outro



Fonte: elaborado pelo autor

sistema. O valor mínimo definido de neurônios foi definido com base na quantidade de dados de entrada do sistema. Em seguida foi duplicado o valor de neurônios e triplicado, e reduzido novamente entre o valor mínimo (quantidade igual as entradas) e o valor máximo (triplo da quantidade de dados de entrada) esses testes foram feitos e avaliados o menor erro entre esses valores máximos e mínimos;

- Quantidade de camadas ocultas: inicialmente foi realizada apenas a implementação de uma camada de entrada e uma de saída, na sequência foi inserida mais uma e duas camadas ocultas, com quantidade de neurônios iguais a entrada, com o dobro e o triplo de neurônios;
- Quantidade de épocas: as épocas dizem respeito a quantos ciclos a rede realizará para tentar ajustar os pesos dos neurônios para obtenção de um menor erro. Nesse caso, ocorre o efeito de Overfitting, que diz respeito ao sobre treinamento da rede, ou seja, quando uma rede chega em seus valores mínimos de erros entre dados previstos e reais, a rede passa a ser retreinada excessivamente. Dessa forma foi utilizado o algoritmo EarlyStopping, o qual finaliza o treinamento da rede, mesmo antes da finalização da quantidade de épocas pré-setada. Para isso é utilizado o meansquarederror, isso é, o mínimo erro quadrático entre valores previstos e reais, aplicados a uma variação máxima definida e uma sequência de repetições onde não ocorrem oscilações maiores que a variação definida;
- Função de ativação: foram testadas todas as funções de ativação descritas no capítulo de referencial teórico;

- **Largura de janela:** a largura da janela diz respeito a quantidade de dados que serão observados para previsão do valor futuro. Nesse caso deseja-se uma janela que tenha a capacidade de "entender" a tendência dos dados, foram testados janelas de 5, 7 e 10 dias;
- **Bach Size:** trata-se da quantidade de dados que são utilizados para o treinamento da rede. Como os dados serão inseridos em série na rede, foram testados bach size de 1, porém como temos 15 amostras, foi também testado com esse valor. O bach size influencia diretamente no tempo de treinamento da rede, quanto menor mais demorado para compilação do algoritmo, uma vez que é feita a divisão dos dados conforme a definição desse valor;
- **Otimizador:** os dois otimizadores mais utilizados para redes neurais são o Adam e o RMSProp, ambos tratam-se de algoritmos estocásticos com a finalidade de encontrar o menor erro entre os dados previstos e dados reais, fazendo com que os pesos da rede sejam calculados de forma a chegar a um menor erro.

Todos os parâmetros descritos anteriormente devem ser otimizados de forma a encontrar o menor erro possível entre valores previstos pela rede e valores reais. A avaliação desses erros será feita através de métricas matemáticas, as quais serão descritas no próximo capítulo

5.2.2.3 Métricas de avaliação

A precisão de um preditor refere-se a quantidade de acertos ou o quão próximo o preditor consegue chegar dos valores reais. Em séries temporais são realizados cálculos específicos para verificar o erro, levando em consideração todas os valores reais e preditos da séries de dados (ARMSTRONG; COLLOPY, 1992) (SHCHERBAKOV et al., 2013) (SAIGAL; MEHROTRA, 2012) (DOUCOURE; AGBOSSOU; CARDENAS, 2016). Entre as técnicas de avaliação do erro de predição para séries temporais podemos destacar:

- **MAE:** trata-se do erro absoluto médio ou desvio absoluto médio;

$$MAD = \sum_{i=0}^n (|A_t - F_t|) / n \quad (5.10)$$

- **MSE:** é o erro quadrado médio, utilizado para verificar a variabilidade nos erros da previsão, muito similar ao R^2 descrito para medição de correlações, o MSE representa o tamanho típico do erro;

$$MSE = \sum_{i=0}^n (A_t - F_t)^2 / n \quad (5.11)$$

- **RMSE:** mede a magnitude média do erro, como os erros são elevador ao quadrado o

RMSE é utilizado principalmente quando erros grande são indesejáveis;

$$RMSE = \sqrt{\sum_{i=0}^n (A_t - F_t)^2 / n} \quad (5.12)$$

- MAPE: trata-se do erro percentual absoluto médio, ou seja, uma relação percentual do erro entre os dados reais e os previstos.

$$MAPE = \sum_{i=0}^n (|(A_t - F_t)/A_t|) / n \cdot 100 \quad (5.13)$$

Nos quais:

A_t : valor real da série de dados para um determinado período de tempo;

F_t : valor predito da série de dados para o mesmo período de tempo do valor real;

n : número de dados da série com relação ao período de tempo.

O cálculo dos valores de MAE, MSE, RMSE e MAPE mostrará o quanto os valores reais estão próximo dos valores previstos pelo algoritmo de Aprendizado de Máquina. Sendo assim, os resultados alcançados para essa dissertação de mestrado são mostrados no próximo capítulo.

6 RESULTADOS E DISCUSSÃO

Nesse capítulo serão descritos os resultados obtidos para avaliação dos sensores que foram utilizados na montagem do protótipo, bem como a avaliação do protótipo desenvolvido. Na sequência serão apresentados os resultados obtidos através dos modelos de Aprendizado de Máquina desenvolvidos.

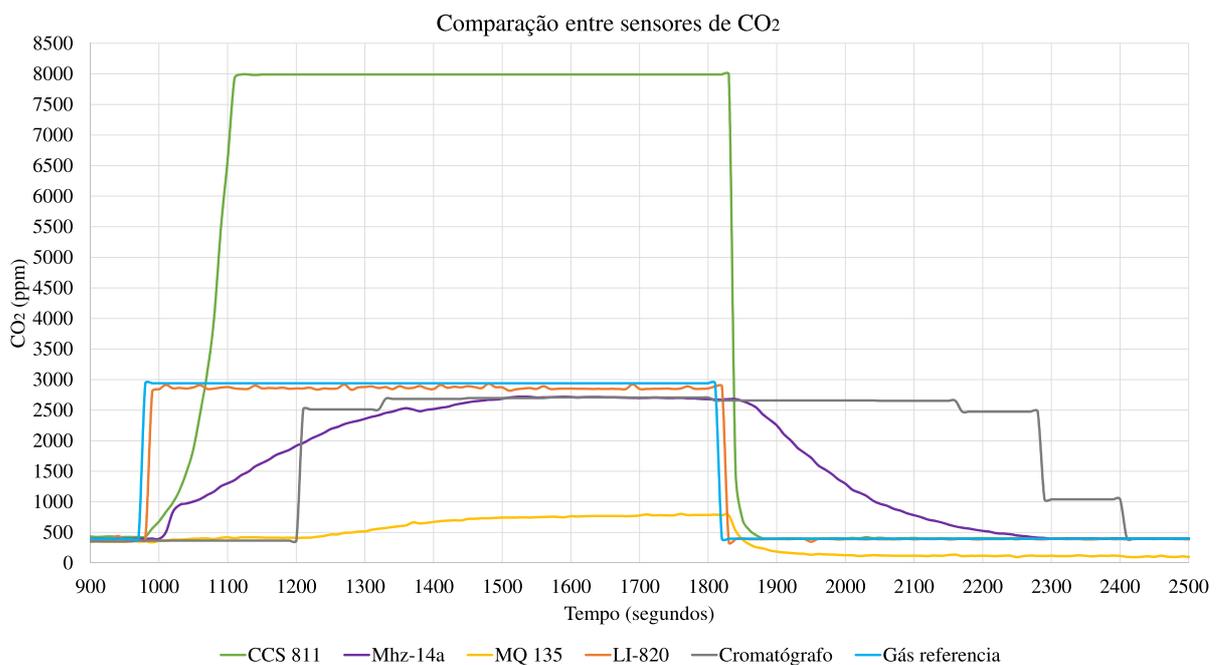
6.1 Avaliação dos sensores

Aqui serão apresentados os resultados obtidos nos testes de seleção dos sensores de medição de CO_2 , umidade do solo, temperatura e fluxo de ar, que irão compor o módulo de IoT do IoTBio. Os valores resultantes das tabelas aqui apresentadas são oriundos de uma calibração realizada em cada um dos sensores. As planilhas desenvolvidas para essas calibrações estão anexadas ao final do trabalho.

6.1.1 Sensor de CO_2

Os resultados obtidos para o sensor de CO_2 podem ser verificados na Figura 46.

Figura 46: Comparação entre sensores de CO_2



Fonte: elaborado pelo autor

Para evitar poluição do gráfico de comparação dos sensores, optou-se pela utilização de uma tabela para demonstrar os valores de desvio padrão da calibração realizada.

Tabela 3: Desvio padrão dos sensores de CO_2 , o desvio padrão foi calculado para uma amostra de 31 medições ($n = 31$)

Sensor	Média das medições de CO_2 (ppm)	Desvio padrão (ppm)
CCS 811	7992	-
Mhz-14a	2703	13
Mq135	773	15
LI-820	2859	18
Cromatógrafo	2703	16
Gás padrão	2940	60

Fonte: elaborado pelo autor

Pode-se perceber que o cromatógrafo e o sensor Li-820 possuem uma resposta mais rápida, quando comparados com os demais sensores, pois logo após a injeção de CO_2 os mesmos já demonstram os resultados da composição do gás. O sensor Mhz-14a também atinge valores satisfatórios, porem é necessário um tempo de aproximadamente 1200 segundos (20 minutos) para sua estabilização. Os demais sensores não apresentaram resultados satisfatório. Para realização desses teste, é importante salientar, que não foi feito nenhum tipo de calibração ou curva de calibração para os sensores. O sensor MQ135, apresenta uma curva bem característica, mesmo que com valores muito inferiores. Uma alternativa seria realizar uma curva de calibração para o mesmo e refazer os testes para verificar os novos valores de medição, porem isso demandaria mais tempo e investimento em um novo cilindro de gás padrão. Diante desses resultados optou-se pela utilização do sensor Mhz-14A por possui boas respostas quanto a análise de CO_2 e custo baixo de investimento quando comparado com os sensores LI-820 e o cromatógrafo.

6.1.2 Sensor de umidade do solo

Um grande diferença do protótipo desenvolvido nessa dissertação é o controle de umidade por sensores. Não foi encontrado na literatura nenhum trabalho que fizesse o controle de umidade por sensores e irrigadores de forma automática.

Foi realizado uma calibração do sensor de umidade do solo para avaliar o seu funcionamento. Nos primeiros testes percebeu-se que após um determinado tempo de utilização os sensores apresentavam variações em seus resultados, foi aonde verificou-se que as laterais dos mesmos não eram isoladas quanto a permeação de água, dessa forma foi necessária a utilização de uma resina a base de epóxi para isolamento, após essa intervenção os sensores tiveram funcionamento satisfatório durante todos os testes. Os resultados de calibração do sensor de umidade do solo é apresentado na tabela 4.

Tabela 4: Calibração sensor de umidade do solo capacitivo, o desvio padrão foi calculado para uma amostra de 10 medições (n = 10)

Sartorius Analisador de umidade	Leitura do sensor	leitura analógica	Desvio padrão
0	0	573	1
20	21	580	1
52	50	365	2
100	101	289	1

Fonte: elaborado pelo autor

6.1.3 Sensor de medição de fluxo de ar

Conforme descrito no capítulo 5, será utilizado um único sensor de fluxo de ar. A Tabela 5 mostra os valores das medições de fluxo do sensor Aalborg a ser utilizado. Esse sensor possui uma saída analógica de 0 a 5 V possibilitando a medição online do fluxo de ar que esta passando pelo sensor de CO_2 .

Tabela 5: Calibração sensor de fluxo de ar, o desvio padrão foi calculado para uma amostra de 10 medições (n = 10)

Valor de referência	Leitura do sensor	Desvio padrão
100	100	2
400	403	2
600	604	1

Fonte: elaborado pelo autor

6.1.4 Sensor de Temperatura

Para garantir a estabilidade da temperatura da estufa foi realizado uma calibração de homogeneidade. Foram posicionados nove sensores de temperatura no interior do equipamento sendo monitorados por quatro horas através de um Data Logger Novus.

Conforme os resultados demonstrados na Tabela 6, é possível perceber que o equipamento demonstrou uma variação máxima de 0,97 °C com um desvio padrão máximo de 0,32 °C, ou seja, valores aceitáveis de acordo com o parâmetro de referência para temperatura de teste.

Todos os sensores foram calibrados com a finalidade de verificar a resposta de cada um e garantir o perfeito funcionamento do protótipo desenvolvido.

6.1.5 Avaliação geral do módulo de IoT

Após a integração de todos os sensores e montagem do protótipo de teste, foi realizada a avaliação do módulo IoT através de três diferentes metodologias de controle de umidade do

Tabela 6: Teste de homogeneidade, o desvio padrão foi calculado para uma amostra de 30 medições (n = 30)

Sensor	Temperatura	Desvio padrão
Sensor 1	60,38	0,32
Sensor 2	60,97	0,19
Sensor 3	60,54	0,25
Sensor 4	60,74	0,21
Sensor 5	60,64	0,16
Sensor 6	60,74	0,21
Sensor 7	60,65	0,31
Sensor 8	60,53	0,21
Sensor 9	60,65	0,25

Fonte: elaborado pelo autor

solo, conforme será descrito no capítulo 5. Foi realizado um experimento durante 45 dias, utilizando como composto de teste, pó de celulose, o qual sabe-se que deve ter uma biodegradabilidade de 70 % e os resultados podem ser verificados na Figura 47.

Observando o gráfico da Figura 47 é possível perceber a importância do controle de umidade do solo por sensores. A automatização do controle de umidade melhorou significativamente a emissão de CO_2 pelos microorganismos presentes no composto de teste, fazendo com que o material de referência (celulose) atingisse o percentual mínimo descrito pelas normas de referência em um período de 45 dias corridos. Ao final dos testes pode-se perceber que o controle preciso de umidade é fundamental para garantir a validade dos testes. O controle de umidade automatizado garantiu que a celulose chegasse a 72 % de biodegradabilidade.

Ao final dos 45 dias de teste, foi utilizado um reator contendo apenas solo para verificar a umidade relativa contida no mesmo, para essa análise foi utilizada a norma (D2216-19, 2019) que descreve como realizar a medição padronizada de umidade contida em solos, foi utilizado um equipamento da marca Sartorius modelo mark 3 e os resultados são demonstrados na Tabela 7.

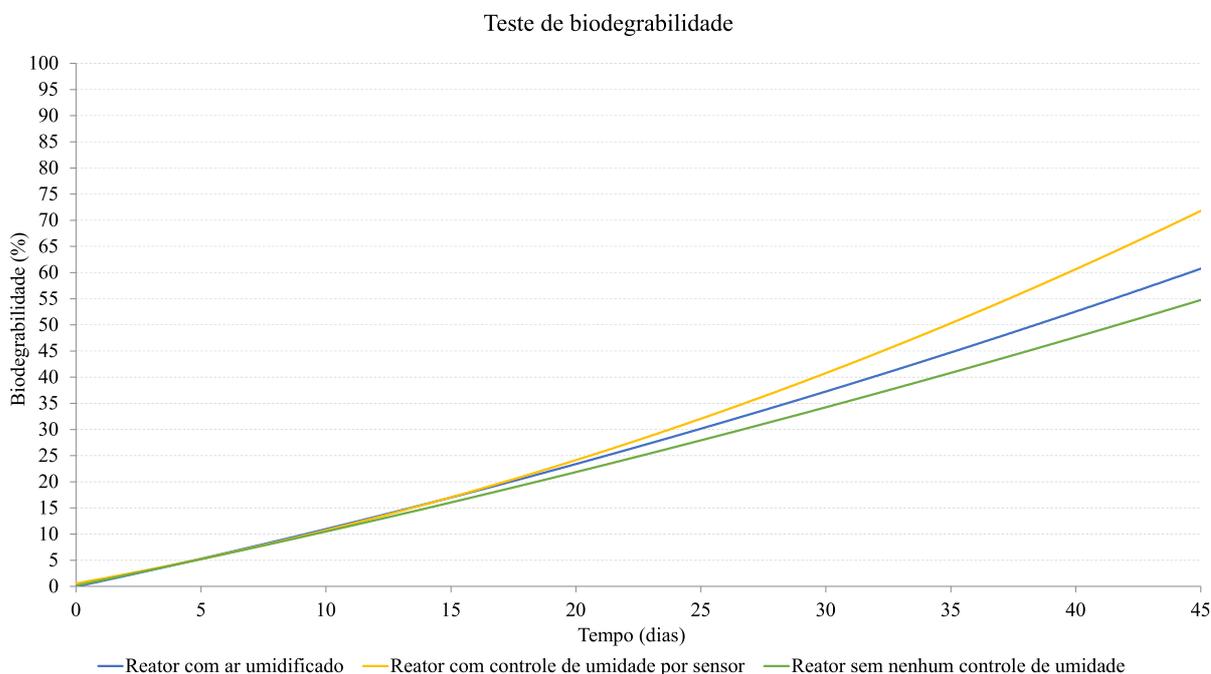
Tabela 7: Medição de umidade para avaliação do controle de umidade do modelo ao final dos 45 dias de teste, o desvio padrão foi calculado para uma amostra de 3 medições (n = 3)

Método	Medição de umidade (%UR)	Desvio padrão (%UR)
Umidificação do ar conforme norma	11,8	0,19
Controle de umidade por sensor	44,5	2,12
Nenhum controle de umidade	8,1	0,47

Fonte: elaborado pelo autor

Os resultados apresentados na Tabela 7 e Figura 47 validam a metodologia de controle de umidade do solo por sensores e dispositivos de irrigação e o protótipo como um todo, permitindo

Figura 47: Resultado final da avaliação do módulo de IoT proposto, no qual é demonstrado claramente que apenas os reatores com controle de umidade por sensores atingiram os valores mínimos esperados para o material padrão, utilizado no teste



Fonte: elaborado pelo autor

que essa configuração seja utilizada na montagem final do equipamento de biodegradabilidade de materiais poliméricos.

Após a avaliação e verificação de resultados positivos junto ao módulo de IoT, passou-se então a trabalhar nas implementações dos algoritmos de aprendizado de máquina para predição de resultados, que serão descritos a seguir.

6.2 Predição de resultados

Todos os algoritmos implementados foram desenvolvidos em Python, utilizando como compilador o Anaconda Spyder 3. Serão, agora, apresentados os resultados de todos os desenvolvimentos desde o pré-processamento até a predição dos resultados.

6.2.1 Análise dos dados

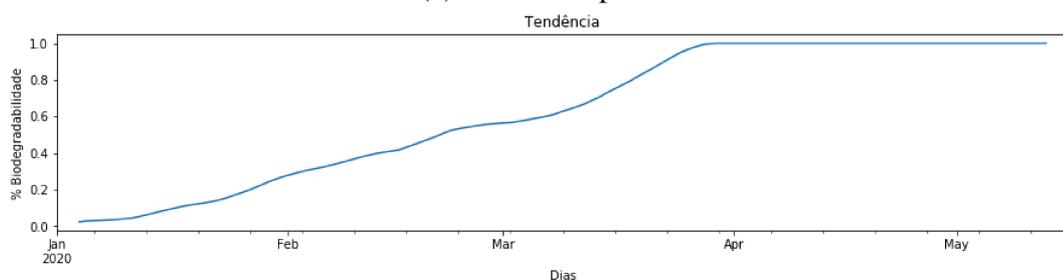
As séries temporais podem ser compostas por três componentes: tendência, sazonalidade e resíduo. Essas componentes podem ser extraídas das séries de dados facilitando a visualização do comportamento dos dados que serão trabalhados. Para decomposição das séries foi utilizado um algoritmo em Python com a biblioteca Statsmodels. As Figuras 48(a) 48(b) 48(c) e 48(d) mostram o resultado de um teste de percentual de biodegradabilidade de material polimérico que atinge 100 % de biodegradabilidade com aproximadamente 90 dias de teste. Percebe-se que os

dados possuem um tendência muito forte, enquanto a sazonalidade e o resíduo são fracos, ou seja, possuem baixos valores em amplitude.

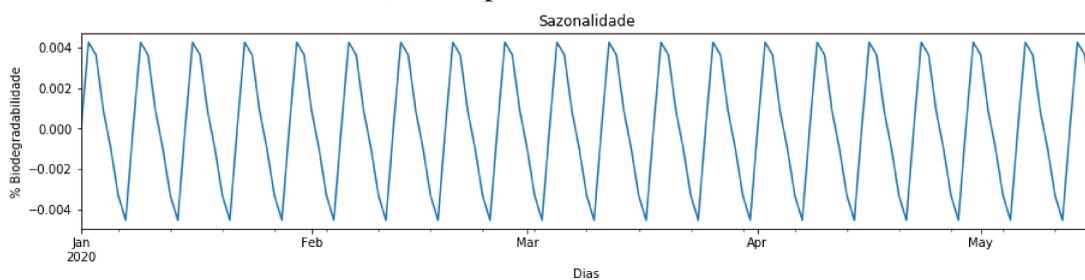
Figura 48: Análise dos comportamento dos dados das séries de determinação do percentual de biodegradabilidade de materiais poliméricos, através da decomposição das séries nas componentes: tendência, sazonalidade e resíduo



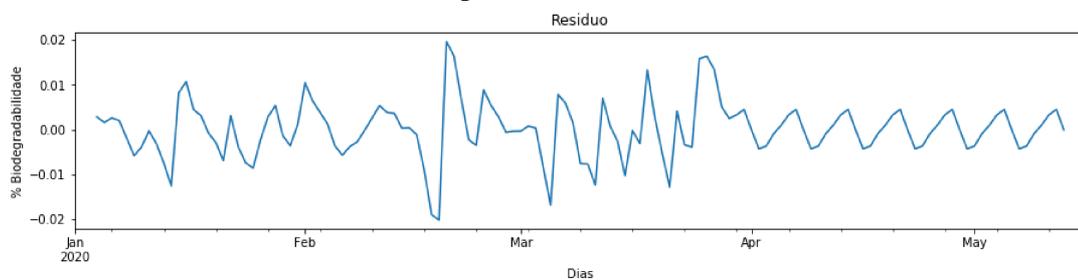
(a) Série Completa



(b) Componente Tendência



(c) Componente Sazonalidade



(d) Componente Resíduo

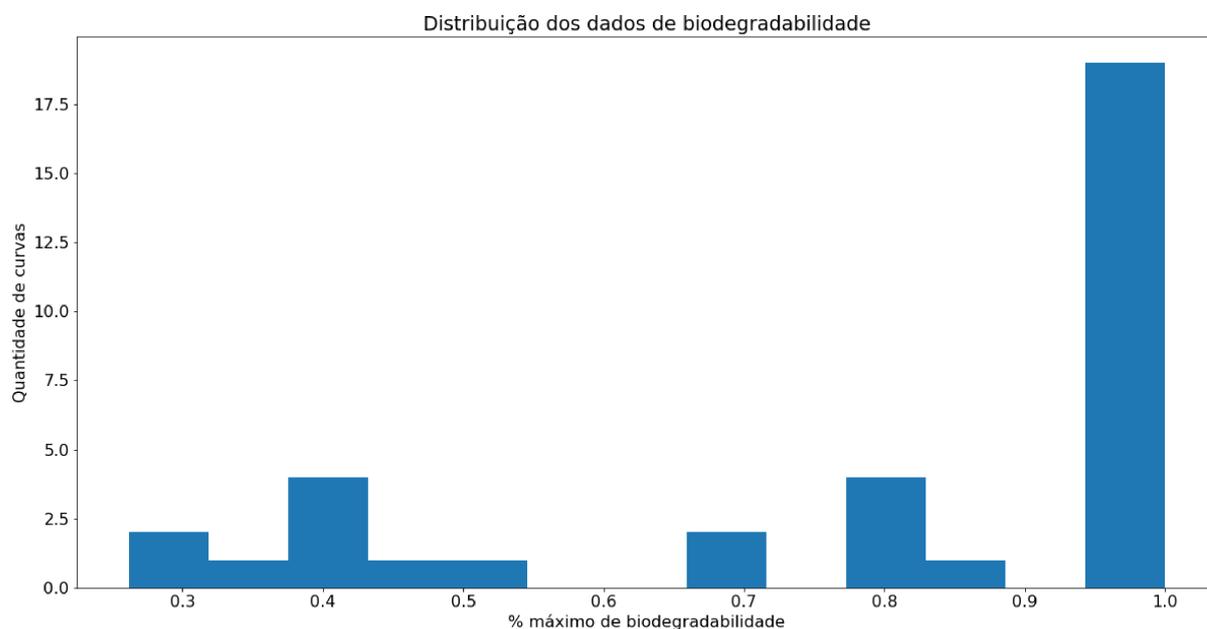
Fonte: elaborados pelo autor

6.2.2 Pré-processamento

Em posse das curvas dos polímeros já ensaiados, foi verificada a correlação entre cada uma delas através da matriz de correção. Esse teste tem como finalidade a verificação de outliers, garantindo assim a qualidade do dataset e dos resultados que serão emitidos pelos algoritmos de Aprendizado de Máquina. A matriz de correlação mostra que quatro (4) séries de dados possuem diferenças significativas quando comparada com as demais. Sendo assim, as mesmas serão excluídas do dataset.

Após o levantamento dos testes de biodegradabilidade já realizados e a exclusão dos outliers, foi verificada a distribuição dos dados. A distribuição pode ser observada na Figura 49. Pode-se perceber que existe uma quantidade maior de polímeros que atingiram 100 % de biodegradabilidade e isso pode ocasionar um erro de overtraining conforme descrito no capítulo anterior. Sendo assim, é necessário fazer uma seleção do conjunto de dados de forma que exista um equilíbrio entre os mesmos.

Figura 49: Representação gráfica da distribuição dos dados de ensaios de biodegradabilidade levantados. O gráfico abaixo mostra um desequilíbrio entre os percentuais de biodegradabilidade, aonde percebe-se uma maior quantidade de ensaios com 100 % de biodegradabilidade para os materiais que já se possui o valor percentual de biodegradabilidade



Fonte: elaborado pelo autor

Novamente foi utilizado o teste de correlação e verificadas quais amostras que possuem valores de 100 % de biodegradabilidade, porém com menor correlação, pois dessa forma teremos um dataset com curvas de comportamento diferenciados. Foram separadas algumas curvas para serem utilizadas na verificação da acurácia dos algoritmos, sendo uma curva com valor máximo de 100 %, uma com valor de aproximadamente 80 % e uma última com valor de aproximadamente 40 %. O dataset de treinamento final possui quinze (15) curvas de polímeros

diferentes que serão utilizado na implementação dos algoritmos de Aprendizado de Máquina. Os resultados dos algoritmos utilizados são apresentados a seguir.

6.2.2.1 Resultados - ARIMA

Alguns dos resultados alcançados para o algoritmo de ARIMA serão apresentados a seguir, junto dos parâmetros (p,d,q) utilizados. Vários foram os testes para otimização foram feitos, porém a demonstração de todos carregaria demais o trabalho, dessa forma serão apresentados alguns dos principais resultados até chegar nas menores diferenças entre valores reais e previstos pela rede.

Foi escolhido 100 dias de teste real como entrada do algoritmo, ou seja, serão previstos 30 dias no futuro com base nos dados disponíveis que possuem 130 dias de análise do percentual de biodegradabilidade para diferentes tipos de polímeros. Os resultados encontrados para os diferentes parâmetros são apresentados na Tabela 8.

Tabela 8: Parâmetros utilizados nos testes de otimização de (p,d,q) do ARIMA, não foram encontrados parâmetros que resultassem em um valores baixos de erros entre valores reais e previstos, essa avaliação será descrita no capítulo de discussão dos resultados, valores médios calculados para uma amostra de 3 medições ($n = 3$)

Parâmetros	Teste 01	Teste 02	Teste 03	Teste 04	Teste 05	Teste 06	Teste 07	AutoARIMA
p	0	1	0	0	1	2	2	1
d	0	0	1	0	1	0	1	1
q	0	0	0	1	1	1	1	2
Avaliação Polímero 40 % :								
MAE:	0,224	0,061	0,008	0,221	0,008	-	0,008	0,008
MSE:	0,005	0,004	0,001	0,050	0,001	-	0,001	0,01
RMSE:	0,226	0,068	0,010	0,224	0,010	-	0,010	0,010
MAPE:	2355,566	646,827	377,969	2330,511	379,884	-	379,728	379,894
Avaliação Polímero 100 % :								
MAE:	0,516	0,004	0,191	0,508	0,180	0,001	0,171	0,171
MSE:	0,266	0,00002	0,048	0,260	0,044	0,000001	0,040	0,040
RMSE:	0,516	0,005	0,220	0,510	0,210	0,001	0,201	0,200
MAPE:	1910,866	16,37	710,100	1880,858	669,650	4,390	636,188	633,485
Avaliação Polímero 80 % :								
MAE:	0,144	0,019	0,153	0,145	0,134	0,178	0,144	-
MSE:	0,020	0,0004	0,030	0,021	0,028	0,048	0,032	-
RMSE:	0,144	0,002	0,175	0,146	0,168	0,211	0,180	-
MAPE:	661,566	88,986	703,180	669,481	618,655	821,727	663,09	-

Fonte: elaborado pelo autor

É possível perceber que nem todos os parâmetros são aplicados a todas as séries de dados disponível, isso acontece devido ao comportamento das séries utilizadas e o comportamento dos parâmetros p, d, q do ARIMA. É verificado também que os erros entre valores previstos e valores reais ficaram muito elevados. No próximo capítulo serão apresentados os resultados para o algoritmo de RNA e em seguida serão discutidos os resultados entre as previsão de ARIMA e RNA.

6.2.2.2 Resultados - Algoritmo RNA com aplicação de LSTM

Alguns dos resultados alcançados para o algoritmo de ARIMA serão apresentados a seguir, junto dos parâmetros utilizados alcançar os mesmos. Vários foram os testes para otimização da rede, porém a demonstração de todos, carregaria demais o trabalho, dessa forma serão apresentados alguns dos principais resultados até chegar nas menores diferenças entre valores reais e previstos pela rede. Alguns testes preliminares foram feitos para verificar uma quantidade adequada de dias reais de teste de entrada da rede, que correspondessem a uma boa resposta de previsão, desse forma, foi escolhido 50 dias de teste real como entrada da rede, ou seja, serão previstos 80 dias no futuro. Após a otimização dos parâmetros será apresentado uma nova tabela (Tabela 10) que irá mostrar a avaliação das métricas por dias reais de entrada da rede. A Tabela 9 mostra alguns dos parâmetros utilizados para otimização da rede.

Tabela 9: Parâmetros utilizados nos testes de otimização da rede neural, os dados em negrito representam os melhores resultados alcançados para os parâmetros de MAE, MSR, RMS e RMSE para polímeros com percentual de biodegradabilidade máximos de 40 %, 100%, e 80%, valores médios calculados para uma amostra de 3 medições (n = 3)

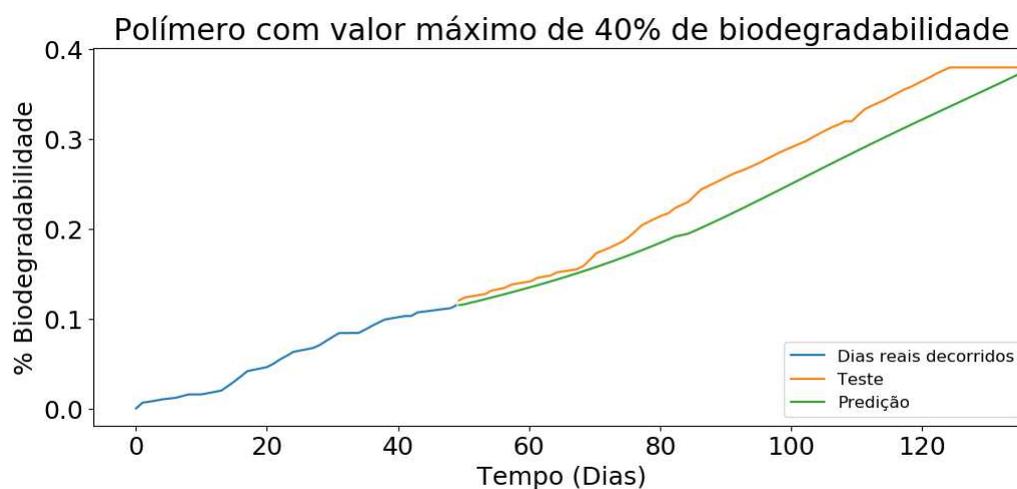
Parâmetros	Teste 01	Teste 02	Teste 03	Teste 04	Teste 05	Teste 06	Teste 07	Teste 08	Teste 09	Teste 10
Quantidade de neurônios:	15	30	30	40	60	30 e 60	30 e 60	30 e 60	60 e 120	40 e 80
Quantidade de camadas ocultas:	1	1	1	1	1	2	2	2	2	2
Quantidade de épocas:	100	100	100	100	100	100	100	100	100	100
Função de ativação:	sigmóide	sigmóide	sigmóide	sigmóide	sigmóide	sigmóide	sigmóide	sigmóide	sigmóide	sigmóide
Largura de janela:	5	5	7	5	5	10	5	10	10	5
Bach Size:	1	15	15	15	15	15	1	15	15	15
Otimizador:	adam	adam	adam	adam	adam	adam	adam	rmsprop	adam	adam
Avaliação Polímero 40 % :										
MAE:	0,328	0,085	0,169	0,070	0,045	0,027	0,124	0,022	0,283	0,110
MSE:	0,128	0,011	0,046	0,006	0,002	0,0009	0,022	0,0008	0,113	0,018
RMSE:	0,358	0,107	0,216	0,079	0,051	0,031	0,148	0,029	0,336	0,137
MAPE:	125,018	32,427	64,529	26,926	17,361	10,529	47,239	8,598	107,923	42,036
Avaliação Polímero 100 % :										
MAE:	0,184	0,160	0,121	0,146	0,164	0,115	0,255	0,183	0,101	0,156
MSE:	0,041	0,029	0,018	0,026	0,031	0,017	0,076	0,040	0,012	0,028
RMSE:	0,203	0,173	0,136	0,162	0,176	0,131	0,275	0,201	0,110	0,168
MAPE:	21,393	18,521	14,013	16,943	19,002	13,314	29,527	21,194	11,716	18,058
Avaliação Polímero 80 % :										
MAE:	0,047	0,013	0,026	0,004	0,006	0,063	0,068	0,027	0,055	0,010
MSE:	0,002	0,000	0,0007	0,00005	0,00005	0,005	0,004	0,0009	0,003	0,0001
RMSE:	0,049	0,014	0,027	0,007	0,007	0,072	0,069	0,030	0,060	0,012
MAPE:	5,937	1,68	3,284	0,547	0,778	8,028	8,594	3,450	7,034	1,324

Fonte: elaborado pelo autor

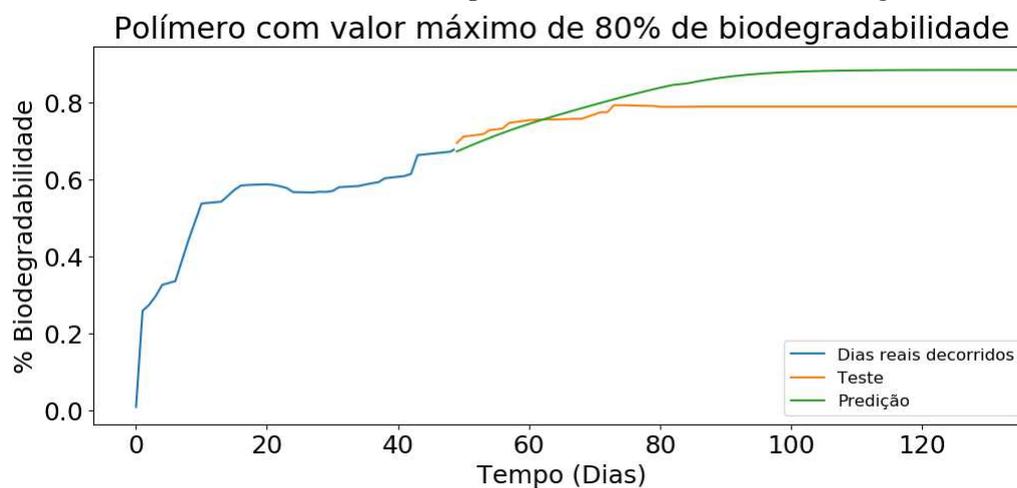
Conforme os resultados apresentados na Tabela 9 é possível perceber que os melhores valores para as métricas de avaliação foram encontrados pelo Teste 06. Com isso a Figura 50(a) apresenta os valores previstos e reais para um polímero que atinge um valor máximo de biodegradabilidade de 40 %, a Figura 50(c) apresenta os valores previstos e reais para um polímero que atinge um valor máximo de biodegradabilidade de 100 % e a Figura 50(b) apresenta os valores previstos e reais para um polímero que atinge um valor máximo de biodegradabilidade de 80 %. É possível perceber que os erros máximos percentuais entre valores previstos e reais são de 13,314 %. Julgamos que esses valores são satisfatório uma vez que ainda possuímos poucos dados para treinamento da rede. Além disso, a norma (ISO; STANDARD, 2012) solicita que os testes de determinação do percentual de biodegradabilidade sejam realizados em triplicata, ou seja, 3 reatores com a amostra em teste e um dos requisitos para validade dos resultados é que os reatores devem ter uma variação máxima nos resultados de 20 %. Dessa forma entendemos que os resultados alcançados são adequados para esse tipo de ensaio.

Após a otimização da rede, foi realizado alguns testes para verificar a acurácia do algoritmo com relação ao período de teste realizado e previsto. Foi inserido na rede um teste com 30, 40, 50 e 60 dias de ensaio já realizado. Os resultados são apresentados na Tabela 10.

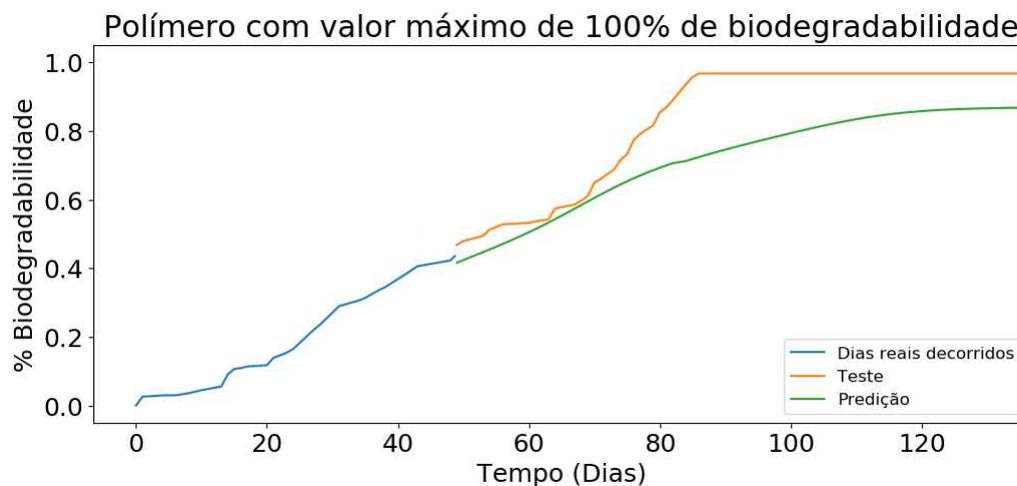
Figura 50: Resultados para o teste 06 com dados de entrada igual a 50 dias reais



(a) Polímero com valor máximo de aproximadamente 40 % de biodegradabilidade



(b) Polímero com valor máximo de aproximadamente 80 % de biodegradabilidade



(c) Polímero com valor máximo de 100 % de biodegradabilidade

Fonte: elaborados pelo autor

Tabela 10: Avaliação da acurácia para 30, 40, 50, 60, 70 e 80 dias de teste real já ocorrido, a partir de 40 dias reais de teste o algoritmo já tem capacidade de fazer previsões com erro percentual aceitável. Os erros reduzem gradativamente conforme os dias reais de teste aumentam, valores médios calculados para uma amostra de 3 medições (n = 3)

Métrica de avaliação	30 dias reais	40 dias reais	50 dias reais	60 dias reais	70 dias reais	80 dias reais
Avaliação Polímero 40 % :						
MAE:	0,0262	0,020	0,027	0,018	0,026	0,008
MSE:	0,001	0,0006	0,0009	0,0004	0,0008	0,0001
RMSE:	0,031	0,025	0,031	0,021	0,028	0,001
MAPE:	11,333	8,443	10,529	6,717	8,820	2,585
Avaliação Polímero 100 % :						
MAE:	0,210	0,138	0,115	0,112	0,135	0,103
MSE:	0,058	0,024	0,017	0,016	0,021	0,011
RMSE:	0,241	0,156	0,131	0,128	0,145	0,105
MAPE:	27,376	16,990	13,314	12,44	14,244	10,473
Avaliação Polímero 80 % :						
MAE:	0,064	0,059	0,063	0,074	0,069	0,077
MSE:	0,005	0,004	0,005	0,006	0,005	0,006
RMSE:	0,071	0,069	0,072	0,079	0,077	0,081
MAPE:	8,421	7,604	8,028	9,246	8,643	9,595

Fonte: elaborado pelo autor

Com base na Tabela 10 é possível perceber que a partir de 40 dias reais de teste o algoritmo já tem capacidade de fazer previsões com erro percentual aceitável, o qual ficam entre 7,6 % e 17,0 %. No próximo capítulo é realizada uma discussão sobre os resultados das implementações do Módulo de aprendizado de Máquina.

6.3 Discussão dos resultados

Os resultados obtidos para o modelo IoTBio provaram de que é possível a implementação de um equipamento para análise de biodegradabilidade de materiais poliméricos automatizado, utilizando técnicas de IoT e Aprendizado de Máquina. Foi possível atingir resultados satisfatórios tanto para implementação do módulo de IoT quanto do módulo de Aprendizado de Máquina.

Para o módulo de IoT, foram testados cinco sensores de medição de CO_2 (Mhz-14a, MQ135, Cromatógrafo, LI-820 e CCS811), os modelos Mq135 e CCS811 não apresentaram resultados satisfatórios quando comparados com o gás padrão. O sensor Li-820 e o cromatógrafo mostraram-se satisfatórios, porém os mesmos possuem valores de aquisição muito elevados, impossibilitando o desenvolvimento de um equipamento de baixo valor, dessa forma optou-se pela utilização do sensor Mhz-14a. Além da calibração do sensor antes de sua escolha, foi também verificado que seu funcionamento continua adequado mesmo após um ano de uso.

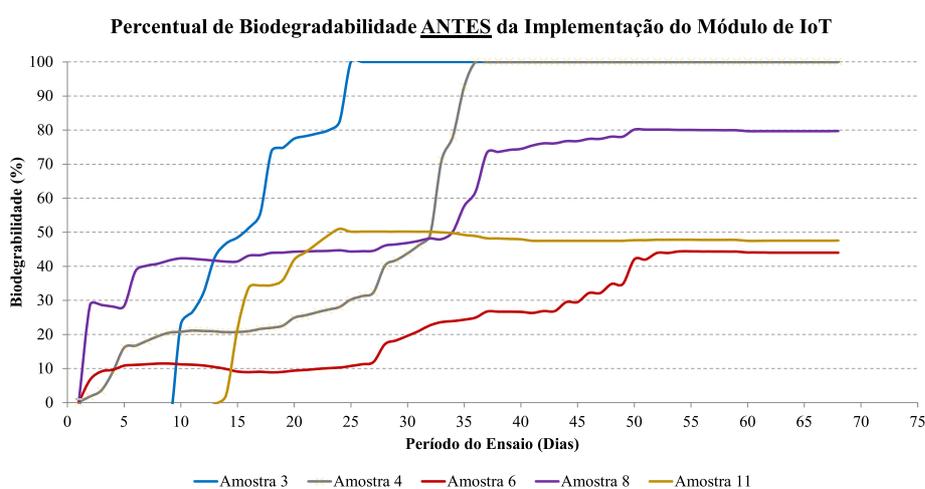
Na implementação do módulo de IoT também foi testado um sensor de umidade do solo capacitivo de baixo custo. O mesmo manteve seu funcionamento em condições adequadas mesmo após um ano de utilização, demonstrando uma nova metodologia de medição de umidade do solo de baixo valor e valores de medição coerentes. As metodologias de medição de umidade do solo padronizadas por normas, são demoradas e demandam de equipamento de alto custo, além de serem adotadas metodologias de ensaio destrutivos, ou seja, as amostras testadas são inutilizadas, tornando inviável sua aplicação em testes de longo prazo que necessitem de monitoramento da umidade contínuo.

As placas de prototipagem rápida permitiram a implementação do protótipo para avaliação de funcionamento do módulo de IoT. As mesmas se mostraram robustas no que diz respeito da centralização de sensores e dispositivos, mantendo seu funcionamento durante todo o período de teste a avaliação. Já o software de supervisor com Node-red facilitou significadamente o acesso e monitoramento aos dados durante os testes de avaliação, tanto que foi mantido para monitoramento e acompanhamento dos testes nos equipamentos reais desenvolvidos.

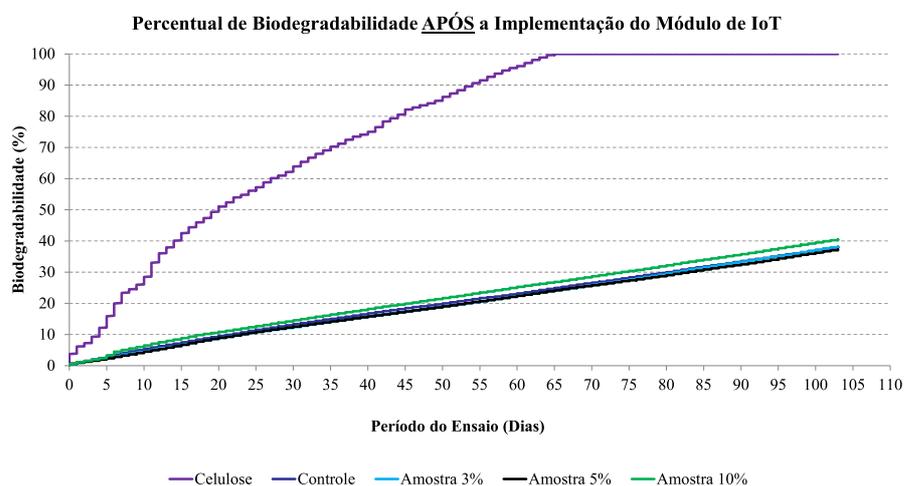
Após a avaliação do protótipo desenvolvido, foram inseridos amostras reais (polímeros reais) para determinação do percentual de biodegradabilidade. Foi possível perceber de acordo com as Figuras 51(a) e 51(b) de que o comportamento das séries temporais após a aplicação das técnicas de IoT para automatização do equipamento, as curvas de monitoramento dos testes possui oscilações e erros baixos, demonstrando uma tendência muito bem caracterizada.

Agora é possível obter dados de forma contínua e em intervalos de tempo constantes. Acredita-se que essas melhorias aconteceram devido ao controle automático sobre todas as variáveis de teste, reduzindo significativamente as intervenções dos operadores junto aos testes. Antes dessa implementação as medições eram feitas apenas nos dias de semana e com intervalos variados. Além de que o controle sobre a umidade do sistema era feita de forma manual.

Figura 51: Comparação entre resultados gráficos gerados antes e após a implementação do módulo de IoT. É possível perceber que os dados gerados pelo protótipo automatizado e sensorizado possuem curvas mais estáveis com menor ruído



(a) Antes do Módulo IoT



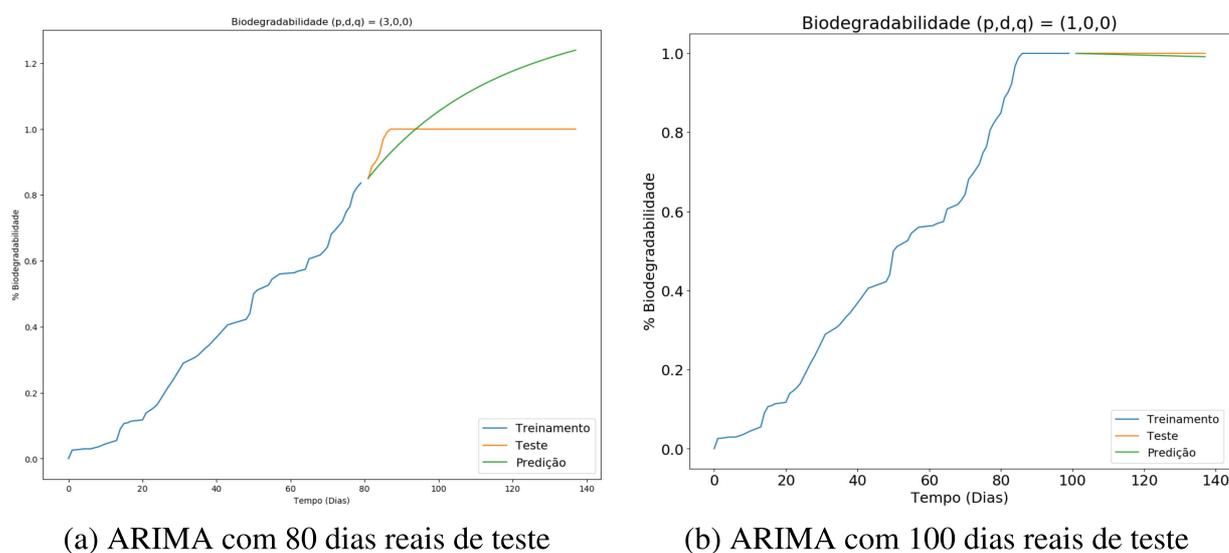
(b) Após o Módulo IoT

Fonte: elaborados pelo autor

Já no módulo de Aprendizado de Máquina, foram implementados dois algoritmos para previsão do percentual de biodegradabilidade de materiais poliméricos. Essas duas implementações serviram para tomada de decisão de qual o melhor metodologia a ser utilizada no módulo Aprendizado de Máquina para compor e fechar o modelo IoTBio. As séries de dados que compõem os testes/ensaio da determinação do percentual de biodegradabilidade,

tratam-se de séries com valores que variam entre 0 % e 100 % e têm como base a emissão de CO_2 liberado pela interação dos micro organismos presentes na amostra em teste. O primeiro algoritmo testado foi o de ARIMA, que trata-se de uma abordagem estatística com base em parâmetros de uma equação (p,d,q) . O segundo algoritmo é baseado em Redes Neurais Artificiais Recorrente do tipo LSTM. As previsões com ARIMA se mostraram insuficientes, conforme pode ser observado nas Figuras 52(a) e 52(b).

Figura 52: Resultados para ARIMA com 100 e 80 dias reais de teste, mesmo variando manualmente os valores p,d,q com o passar dos dias, não é possível chegar a um resultado aceitável para justificar a sua utilização no módulo de Aprendizado de Máquina do IoTBio, mesmo quando variamos os parâmetros p, d, q para diferentes amostras



Fonte: elaborados pelo autor

Percebe-se que mesmo variando os parâmetros p,d,q conforme o aumento dos dias reais de teste. Na figura 52(b) os resultados estão adequados, nesse caso existe uma redução insuficiente do tempo de teste (valores decorrido real de 100 dias), pois nesse caso é iniciada a estabilização dos valores da série de teste, já podendo ser observado o final do ensaio sem a aplicação de nenhum tipo de algoritmo. Acredita-se que os resultados para ARIMA se mostraram insatisfatório pelos seguintes fatores:

1) ARIMA funciona melhor para dados sazonais, aonde os comportamentos são repetidos ao longo do tempo, ou, dados crescentes e decrescentes, no caso das séries que determina o percentual de biodegradabilidade crescem até um determinado patamar e estabilizam;

2) O algoritmo funcionaria adequadamente se já fosse percebido algum tipo de comportamento de estabilização dos dados, nessa ocasião já não é interessante prever os valores futuros, pois já se sabe que o teste esta se aproximando do seu final;

Enquanto a RNA LSTM demonstra que os resultados são satisfatório para previsões de até 90 dias no futuro, ou seja, como os dados disponíveis possuem duração máxima de 130 dias, já foi possível prever o percentual de biodegradabilidade tomando como entrada da rede apenas

40 dias reais de teste, aonde chegou-se a erros entre valores reais e previstos (dados de teste) de 7,6 % e 17,0 %. Isso acontece devido ao treinamento da rede, aonde é mostrado para o modelo quais os comportamento das séries, "ensinando" os padrões de curvas dos ensaios, tornando as redes capazes de prever valores a longo prazo com erros pequenos, mesmo com poucas curvas de treinamento da rede, uma vez que os dados estejam corretamente tratados, filtrados e equilibrados. Com isso fica estabelecido que o melhor algoritmo para compor o módulo de Aprendizado de Máquina do modelo IoTBio é as Redes Neurais Recorrentes do tipo LSTM.

No desenvolvimento desse trabalho foi possível perceber os seguintes pontos positivos:

- Controle automático das variáveis envolvidas na determinação do percentual de biodegradabilidade, principalmente emissão de CO_2 e umidade do solo, reduzindo as intervenções dos operadores com o teste e conseqüentemente o tempo de hora-homem;
- Padronização e aquisição automática das taxas de aquisição dos valores das variáveis envolvidas no processo;
- Melhora significativa nas séries temporais decorrentes dos testes do percentual de biodegradabilidade;
- Avaliação de sensores de baixo custo para medição de dióxido de carbono e umidade do solo, mostrando que os valores dos mesmos são confiáveis;
- Os trabalhos relacionados não contemplavam uma metodologia de teste totalmente automatizando, dependendo do operador em algumas situações, além de não contemplarem a aplicação de algoritmos de Aprendizado de Máquina para redução dos tempos de ensaio;
- O módulo de IoT permitiu a aplicação de algoritmos de Aprendizado de Máquina para previsão dos resultados do percentual de biodegradabilidade, antes mesmo dos tempos reais de teste, os quais podem variar de 90 a 180 dias, foi possível prever o resultado do teste com apenas 40 dias de teste, reduzindo o tempo de ensaio em 30 %;
- Os resultados dos algoritmos de Redes Neurais Artificiais com arquitetura LSTM, se demonstraram eficazes na previsão dos valores finais antes mesmo do tempo real de teste, abrindo portas para sua aplicação em diferentes ensaios envolvendo materiais poliméricos de longa duração.

Algumas limitações, também foram levantadas:

- O número de amostras, polímeros em teste, está limitado a 4 amostras simultâneas, devido a necessidade de realizar o ensaio em triplicata e com material de referência simultaneamente para avaliação;

- No início dos teste é necessário fazer o ajuste dos fluxos de ar de forma manual, uma vez que válvula proporcionais automáticas, as quais fariam o ajuste automático desses fluxos, possuem valores de aquisição elevados;
- Mesmo com toda automatização do sistema é necessário a avaliação do pH das amostras quinzenalmente, uma vez de que não existem medidores de pH para monitoramento contínuo de ambientes sólidos;
- Para redução dos erros dos algoritmos de RNA precisaria-se de uma quantidade maior de dados de ensaios reais, porém é necessário um equilíbrio entre os percentuais de biodegradabilidade desses dados, o que torna difícil o aumento desse banco de dados.

7 CONCLUSÃO

Este trabalho apresentou o modelo IoTBio para realização de ensaios e determinação do percentual de biodegradabilidade de materiais poliméricos. O IoTBio foi implementado, sendo composto por dois grandes módulos, chamados de módulo IoT, no qual foi desenvolvido um protótipo para avaliação, e módulo de Aprendizado de Máquina, no qual foram testados dois possíveis algoritmos previsores.

Para avaliação do módulo IoT, foi desenvolvido um protótipo. Foram estudados alguns sensores de baixo custo. O sensor de CO_2 modelo Mhz-14a teve uma resposta mais lenta quando comparado aos sensores de custo mais alto, porém o sensor mediu corretamente os níveis de CO_2 em uma mistura de gás padrão com valores de CO_2 conhecidos, o que permitiu a sua utilização. Os sensores de umidade do solo e temperatura também apresentaram resultados dentro dos limites aceitáveis. O medidor de vazão, com saída analógica, tornou possível a redução de componentes utilizados, mantendo o monitoramento do fluxo de ar ao longo dos testes nos 18 reatores montados, utilizando um único medidor de vazão e sensor de CO_2 . Ao final dos testes, diferente de outros trabalhos, o equipamento foi totalmente automatizado com controle de umidade do solo através de sensores e dispositivos de irrigação.

A metodologia de controle de umidade do solo, proposta por diferentes trabalhos na área, coloca em dúvida o adequado controle deste parâmetro. Dessa forma, foi realizada a montagem de três configurações diferentes de controle da umidade do solo para validação do mais correto. Três reatores usaram sensores e irrigação automática; os outros três usavam ar umidificado e os três últimos sem controle de umidade. Os reatores com controle de umidade por sensores e irrigação automática foram os únicos que atingiram os resultados esperados dos níveis de emissão de CO_2 , utilizando celulose como material de referência, além de que foram os únicos que mantiveram o valor de umidade próximos ao valor necessário para o teste, medidos ao final do experimento. Isso demonstra que é necessário um controle preciso da umidade para que os resultados do teste sejam válidos. O sucesso do protótipo desenvolvido resultou no depósito de uma patente e na montagem de outros 3 equipamentos, que podem ser observados na Figura 53, os quais já estão em operação e disponíveis para realização de testes a indústrias de desenvolvimento de novos materiais poliméricos no Instituto SENAI de Inovação em Engenharia de Polímeros.

O módulo de IoT permitiu a coleta e armazenamento de dados de ensaios da determinação do percentual de biodegradabilidade, o qual tem duração entre 90 e 180 dias, dependendo da composição do polímero testado. Com o objetivo de reduzir este tempo de teste, foram desenvolvidos dois algoritmos previsores em Python: ARIMA e RNA do tipo LSTM. Durante a otimização e teste dos algoritmos foi possível perceber que apenas RNA foi capaz de prever os valores com erros na faixa de 7,6 % e 17,0 % entre valores reais e previstos, definido o Algoritmo mais adequado para compor o módulo de Aprendizado de Máquina.

Dessa forma, fica estabelecido que o IoTBio é composto por um sistema de sensoriamento

Figura 53: Três equipamentos desenvolvidos com base nos estudos dessa dissertação, foto tirada no Instituto Senai de Inovação em Engenharia de Polímeros - São Leopoldo - Brasil



Fonte: elaborado pelo autor

para monitoramento das variáveis envolvidas no processo (CO_2 , Temperatura, Fluxo de ar, Umidade do Solo e Tempo), dispositivos microprocessados para leitura dos sensores e controle dos atuadores (válvulas de irrigação e direcionamento dos fluxos de ar) e algoritmo de Rede Neural Artificial com arquitetura LSTM para previsão dos valores e redução dos tempos de teste.

A metodologia arquitetada foi estudada, implementada, testada e validada, abrindo portas para um mundo a ser explorado dentro dos testes/ensaios realizados em materiais poliméricos não só para ensaios envolvendo processos de biodegradabilidade, mas também outras metodologias que possuem dados reportados ao longo do tempo, permitindo a utilização de algoritmos de Aprendizado de Máquina para previsão de resultados, reduzindo os tempos de teste, mantendo a qualidade dos resultados e permitindo que as instituições de pesquisa tenham sua capacidade de oferta de ensaios aumentada, contribuindo no desenvolvimento de novas pesquisas e novos materiais poliméricos. Por fim, o desenvolvimento do IoTBio virou case de sucesso junto ao Instituto Senai de Inovação em Engenharia de Polímeros ¹.

7.1 Contribuições

O desenvolvimento do IoTBio concretizou algumas contribuições científicas e tecnológicas. Como contribuições científicas podemos destacar o desenvolvimento de um modelo automatizado com técnicas de IoT que possibilitou a realização automática de ensaios de biodegradabilidade, bem como a implementação de algoritmos de aprendizado de máquina para previsão dos resultados antes mesmo do tempo final de teste. Estas contribuições resultaram na publicação de um artigo junto ao Congresso Brasileiro de Automática, o CBA, o maior congresso de Engenharia Elétrica do Brasil desde 1976 e a submissão de um artigo junto à revista *Computer Standards and Interfaces*.

¹<https://www.senairs.org.br/cases/desenvolvimento-de-camara-automatizada-para-ensaios-biodegradabilidade>

Figura 54: Sensor de umidade do solo portátil e sensor de análise de gases desenvolvido ao longo dessa dissertação



(a) Sensor de umidade do solo desenvolvido, o sensor possibilita a realização de medições da umidade em poucos segundos, o sensor funciona com uma bateria que pode ser recarregada com uma fonte de baixo consumo de energia elétrica



(b) Sensor de análise de gases desenvolvido, o sensor possibilita a análise de dióxido de carbono e metano para utilização em ambientes internos

Fonte: elaborados pelo autor

Além das contribuições científicas, tivemos algumas contribuições tecnológicas, sendo elas: o depósito de uma patente para o equipamento desenvolvido ao longo desta dissertação e desenvolvimento de um sensor portátil com custo de aproximadamente R\$ 50,00, Figura 55(a). Este sensor realiza a medição da umidade do solo em poucos segundos com erros máximos de 2,0 %UR. Antes do desenvolvimento deste sensor, era utilizado um equipamento com valor de aquisição na faixa de R\$ 100.000,00, com consumo de energia elétrica de 1 kW quando as análises eram feitas pela diferença de massa, tendo um tempo médio de análise de 2 a 4 horas. O desenvolvimento deste sensor possibilitou a medição de umidade do solo de outros tipos de ensaios de forma rápida e econômica (tanto pelo custo do equipamento quanto pelo custo do consumo de energia elétrica). Além do sensor de umidade do solo portátil, foi também construído um sensor para análise de gases dióxido de carbono e metano de baixo custo, 55(b) para monitoramento de gases atmosféricos em ambientes fechados. E, para finalizar, as contribuições foi montado um mini protótipo, Figura 56, o qual serviu para exposição junto à feira Mercopar 2020 lugar onde foi demonstrado a empresas e instituições o novo desenvolvimento e a possibilidade de parceira no desenvolvimento de novos materiais biodegradáveis.

7.2 Trabalhos futuros

Como trabalhos futuros a essa dissertação deseja-se realizar os seguintes itens:

Figura 55: Mini protótipo desenvolvido com um único reator para participar da feira Mercopar 2020



(a) Mini protótipo desenvolvido (b) Instalação na Mercopar 2020 (c) Exposição no estande

Fonte: elaborados pelo autor

- Elaboração de um projeto de placa SMD dedicada para instalação nos equipamentos desenvolvidos;
- Atualização do dataset conforme forem sendo realizados novos testes para possível aumento da acurácia dos algoritmos;
- Implementação dos mesmos conceitos aplicados nessa dissertação para implementação de testes de determinação do percentual de biodegradabilidade, utilizando ambiente marinho (água como meio de teste);

REFERÊNCIAS

- Abiplast - Associação Brasileira da Indústria do Plástico. **Perfil 2018**. 2019. Disponível em: <http://www.abiplast.org.br/wp-content/uploads/2019/10/perfil2018-web_VC.pdf>. Access in: march 2020.
- ACHARYA, Mohan S; ARMAAN, Asfia; ANTONY, Aneeta S. A comparison of regression models for prediction of graduate admissions. In: IEEE. **2019 International Conference on Computational Intelligence in Data Science (ICCIDS)**. [S.l.], 2019. p. 1–5.
- ADLA, Soham et al. Laboratory calibration and performance evaluation of low-cost capacitive and very low-cost resistive soil moisture sensors. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 20, n. 2, p. 363, 2020.
- AGGARWAL, Charu C et al. **Neural networks and deep learning**. [S.l.]: Springer, 2018.
- AHMAD, AS et al. A review on applications of ann and svm for building electrical energy consumption forecasting. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 33, p. 102–109, 2014.
- AHMED, Nesreen K et al. An empirical comparison of machine learning models for time series forecasting. **Econometric Reviews**, Taylor & Francis, v. 29, n. 5-6, p. 594–621, 2010.
- AILENI, Raluca Maria et al. Data fusion-based ai algorithms in the context of iiots. In: **Internet of Things for Industry 4.0**. [S.l.]: Springer, 2020. p. 17–38.
- AL-FUQAHA, Ala et al. Internet of things: A survey on enabling technologies, protocols, and applications. **IEEE communications surveys & tutorials**, IEEE, v. 17, n. 4, p. 2347–2376, 2015.
- ALPAYDIN, Ethem. **Introduction to machine learning**. [S.l.]: MIT press, 2020.
- AMARI, Shunichi. A theory of adaptive pattern classifiers. **IEEE Transactions on Electronic Computers**, IEEE, n. 3, p. 299–307, 1967.
- ARDINY, Hadi; WITWICKI, Stefan; MONDADA, Francesco. Construction automation with autonomous mobile robots: A review. In: IEEE. **2015 3rd RSI International Conference on Robotics and Mechatronics (ICROM)**. [S.l.], 2015. p. 418–424.
- ARMSTRONG, J Scott; COLLOPY, Fred. Error measures for generalizing about forecasting methods: Empirical comparisons. **International journal of forecasting**, Elsevier, v. 8, n. 1, p. 69–80, 1992.
- BAHDANAU, Dzmitry; CHO, Kyunghyun; BENGIO, Yoshua. Neural machine translation by jointly learning to align and translate. **arXiv preprint arXiv:1409.0473**, 2014.
- BALBINOT, Alexandre; BRUSAMARELLO, Valner João. **Instrumentação E Fundamentos de Medidas. Volume 3**. [S.l.]: Grupo Gen-LTC, 2019.
- BISHOP, Christopher M et al. **Neural networks for pattern recognition**. [S.l.]: Oxford university press, 1995.
- BOROWIK, A; WYSZKOWSKA, J. Soil moisture as a factor affecting the microbiological and biochemical activity of soil. **Plant, Soil and Environment**, v. 62, n. 6, p. 250–255, 2016.

BOX, George EP et al. **Time series analysis: forecasting and control**. [S.l.]: John Wiley & Sons, 2015.

BROCKWELL, Peter J; DAVIS, Richard A. **Introduction to time series and forecasting**. [S.l.]: springer, 2016.

BUDUMA, Nikhil; LOCASCIO, Nicholas. **Fundamentals of deep learning: Designing next-generation machine intelligence algorithms**. [S.l.]: "O'Reilly Media, Inc.", 2017.

CARDOSO, Régis; COSTA, Cristiano André da; FIGUEIREDO, Rodrigo Marques de. Uma proposta de análise de biodegradabilidade no âmbito da internet das coisas. **Anais da Sociedade Brasileira de Automática**, v. 2, n. 1, 2020.

CARDOSO, Régis; STEFENS, Josemar. Equipamento e método automatizado para determinação da biodegradabilidade de materiais em escala laboratorial. **BR10202002323**, INPI - Instituto Nacional da Propriedade Industrial, 2020.

CASTELLANI, Francesco et al. Measuring the biodegradability of plastic polymers in olive-mill waste compost with an experimental apparatus. **Advances in Materials Science and Engineering**, Hindawi, v. 2016, 2016.

CHAVAN, Gaurav; MOMIN, Bashirahamad. An integrated approach for weather forecasting over internet of things: A brief review. In: IEEE. **2017 International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud)(I-SMAC)**. [S.l.], 2017. p. 83–88.

CINELLI, Patrizia et al. Processability and degradability of pha-based composites in terrestrial environments. **International journal of molecular sciences**, Multidisciplinary Digital Publishing Institute, v. 20, n. 2, p. 284, 2019.

CORRAL-PLAZA, David et al. A stream processing architecture for heterogeneous data sources in the internet of things. **Computer Standards & Interfaces**, Elsevier, v. 70, p. 103426, 2020.

D2216-19, ASTM. **Standard Method of Laboratory Determination of Moisture Content of Soil**. 2019.

D883-20, ASTM. **Standard terminology relating to plastics**. 2019.

DEB, Chirag et al. A review on time series forecasting techniques for building energy consumption. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 74, p. 902–924, 2017.

DIVYA, K Sree; BHARGAVI, P; JYOTHI, S. Machine learning algorithms in big data analytics. **International Journal of Computer Sciences and Engineering**, v. 6, n. 1, 2018.

DOMINGOS, Pedro. A few useful things to know about machine learning. **Communications of the ACM**, ACM New York, NY, USA, v. 55, n. 10, p. 78–87, 2012.

DOUCOURE, Boubacar; AGBOSSOU, Kodjo; CARDENAS, Alben. Time series prediction using artificial wavelet neural network and multi-resolution analysis: Application to wind speed data. **Renewable Energy**, Elsevier, v. 92, p. 202–211, 2016.

DŘÍMAL, Pavel; HOFFMANN, Jaromír; DRUŽBÍK, Martin. Evaluating the aerobic biodegradability of plastics in soil environments through gc and ir analysis of gaseous phase. **Polymer testing**, Elsevier, v. 26, n. 6, p. 729–741, 2007.

EHLERS, Ricardo S. Análise de séries temporais. **Laboratório de Estatística e Geoinformação. Universidade Federal do Paraná**, 2007.

EMADIAN, S Mehdi; ONAY, Turgut T; DEMIREL, Burak. Biodegradation of bioplastics in natural environments. **Waste management**, Elsevier, v. 59, p. 526–536, 2017.

FAWAZ, Hassan Ismail et al. Deep learning for time series classification: a review. **Data Mining and Knowledge Discovery**, Springer, v. 33, n. 4, p. 917–963, 2019.

FILIPPO, GF. Automação de processos e de sistemas. 1. **São Paulo: Érica**, v. 144, 2014.

FRANK, Alejandro Germán; DALENOGARE, Lucas Santos; AYALA, Néstor Fabián. Industry 4.0 technologies: Implementation patterns in manufacturing companies. **International Journal of Production Economics**, Elsevier, v. 210, p. 15–26, 2019.

FUNABASHI, Masahiro; NINOMIYA, Fumi; KUNIOKA, Masao. Biodegradability evaluation of polymers by iso 14855-2. **International journal of molecular sciences**, Molecular Diversity Preservation International, v. 10, n. 8, p. 3635–3654, 2009.

GÉRON, Aurélien. **Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems**. [S.l.]: O'Reilly Media, 2019.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep learning**. [S.l.]: MIT press, 2016.

GREENE, J. Biodegradation of biodegradable and compostable plastics under industrial compost, marine and anaerobic digestion. **Sci. Environ. Bull.**, v. 1, p. 13–18, 2018.

HARRINGTON, Peter. **Machine learning in action**. [S.l.]: Manning Publications Co., 2012.

HAYKIN, Simon. **Neural Networks and Learning Machines, 3/E**. [S.l.]: Pearson Education India, 2010.

HOCHREITER, Sepp; SCHMIDHUBER, Jürgen. Long short-term memory. **Neural computation**, MIT Press, v. 9, n. 8, p. 1735–1780, 1997.

HONG, Miao; CHEN, Eugene Y-X. Future directions for sustainable polymers. **Trends in Chemistry**, Elsevier, v. 1, n. 2, p. 148–151, 2019.

HOSHINO, Akira et al. Study of the determination of the ultimate aerobic biodegradability of plastic materials under controlled composting conditions. **Journal of Polymers and the Environment**, Springer, v. 15, n. 4, p. 275–280, 2007.

INMETRO, A. **estimativa da incerteza de medição pelos métodos do ISO GUM 95 e de simulação de Monte Carlo**. [S.l.], 2008.

ISO, BSEN; STANDARD, BRITISH. Part 1:determination of the ultimate aerobic biodegradability of plastic materials under controlled composting conditions - method by analysis of evolved carbon dioxide (iso 14855-1: 2012. 2012.

JAIN, Raj. **The art of computer systems performance analysis: techniques for experimental design, measurement, simulation, and modeling**. [S.l.]: John Wiley & Sons, 1990.

JORDAN, Michael I; MITCHELL, Tom M. Machine learning: Trends, perspectives, and prospects. **Science**, American Association for the Advancement of Science, v. 349, n. 6245, p. 255–260, 2015.

KAGERMANN, Henning et al. **Industrie 4.0 in a Global Context: strategies for cooperating with international partners**. [S.l.]: Herbert Utz Verlag, 2016.

KAGERMANN, Henning; LUKAS, Wolf-Dieter; WAHLSTER, Wolfgang. Industrie 4.0: Mit dem internet der dinge auf dem weg zur 4. industriellen revolution. **VDI nachrichten**, v. 13, n. 11, p. 2, 2011.

KALE, Gaurav et al. Biodegradability of polylactide bottles in real and simulated composting conditions. **Polymer Testing**, Elsevier, v. 26, n. 8, p. 1049–1061, 2007.

KANAWADAY, Aameeth; SANE, Aditya. Machine learning for predictive maintenance of industrial machines using iot sensor data. In: IEEE. **2017 8th IEEE International Conference on Software Engineering and Service Science (ICSESS)**. [S.l.], 2017. p. 87–90.

KE, Nan Rosemary et al. Focused hierarchical rnns for conditional sequence processing. **arXiv preprint arXiv:1806.04342**, 2018.

KHASHEI, Mehdi; BIJARI, Mehdi. A novel hybridization of artificial neural networks and arima models for time series forecasting. **Applied Soft Computing**, Elsevier, v. 11, n. 2, p. 2664–2675, 2011.

KIJCHAVENGKUL, Thitisilp et al. Development of an automatic laboratory-scale respirometric system to measure polymer biodegradability. **Polymer testing**, Elsevier, v. 25, n. 8, p. 1006–1016, 2006.

KOUICEM, Djamel Eddine; BOUABDALLAH, Abdelmadjid; LAKHLEF, Hicham. Internet of things security: A top-down survey. **Computer Networks**, Elsevier, v. 141, p. 199–221, 2018.

LANG, KJ. The development of the time-delay neural network architecture for speech recognition. **Technical Report CMU-CS-88-152**, Carnegie Mellon University, 1988.

LANGLEY, Pat; SIMON, Herbert A. Applications of machine learning and rule induction. **Communications of the ACM**, ACM New York, NY, USA, v. 38, n. 11, p. 54–64, 1995.

LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning. **nature**, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015.

LIEW, Shan Sung; KHALIL-HANI, Mohamed; BAKHTERI, Rabia. Bounded activation functions for enhanced training stability of deep neural networks on visual pattern recognition problems. **Neurocomputing**, Elsevier, v. 216, p. 718–734, 2016.

LIMA, Isaías; PINHEIRO, Carlos AM; SANTOS, Flávia A Oliveira. **Inteligência artificial**. [S.l.]: Elsevier Brasil, 2016.

LUYT, Adriaan S; MALIK, Sarah S. Can biodegradable plastics solve plastic solid waste accumulation? In: **Plastics to Energy**. [S.l.]: Elsevier, 2019. p. 403–423.

MADAKAM, Somayya et al. Internet of things (iot): A literature review. **Journal of Computer and Communications**, Scientific Research Publishing, v. 3, n. 05, p. 164, 2015.

MAHDAVINEJAD, Mohammad Saeid et al. Machine learning for internet of things data analysis: A survey. **Digital Communications and Networks**, Elsevier, v. 4, n. 3, p. 161–175, 2018.

MARTÍNEZ-ÁLVAREZ, Francisco et al. A survey on data mining techniques applied to electricity-related time series forecasting. **Energies**, Multidisciplinary Digital Publishing Institute, v. 8, n. 11, p. 13162–13193, 2015.

MCCULLOCH, Warren S; PITTS, Walter. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, Springer, v. 5, n. 4, p. 115–133, 1943.

MEDSKER, Larry R; JAIN, LC. Recurrent neural networks. **Design and Applications**, v. 5, 2001.

MELLIT, Adel; KALOGIROU, Soteris A. Artificial intelligence techniques for photovoltaic applications: A review. **Progress in energy and combustion science**, Elsevier, v. 34, n. 5, p. 574–632, 2008.

MIKELL, P. **Automação industrial e sistemas de manufatura**. [S.l.]: Pearson Brasil, 2011.

MONTGOMERY, Douglas C; RUNGER, George C. **Applied statistics and probability for engineers**. [S.l.]: John Wiley & Sons, 2010.

MUHURI, Pranab K; SHUKLA, Amit K; ABRAHAM, Ajith. Industry 4.0: A bibliometric analysis and detailed overview. **Engineering applications of artificial intelligence**, Elsevier, v. 78, p. 218–235, 2019.

NAGELKERKE, Nico JD et al. A note on a general definition of the coefficient of determination. **Biometrika**, Oxford University Press, v. 78, n. 3, p. 691–692, 1991.

NILSSON, Nils J. **Principles of artificial intelligence**. [S.l.]: Morgan Kaufmann, 2014.

OLAH, Christopher. Understanding lstm networks. 2015.

ÖZGÜN, Onur; BARLAS, Yaman. Discrete vs. continuous simulation: When does it matter. In: **Proceedings of the 27th international conference of the system dynamics society**. [S.l.: s.n.], 2009. v. 6, p. 1–22.

PACCHINI, Athos Paulo Tadeu et al. The degree of readiness for the implementation of industry 4.0. **Computers in Industry**, Elsevier, v. 113, p. 103125, 2019.

Plastics Europe - Association of Plastics Manufactures. **Plastics – the Facts 2019 - An analysis of European plastics production, demand and waste data**. 2019. Disponível em: <https://www.plasticseurope.org/application/files/1115/7236/4388/FINAL_web_version_Plastics_the_facts2019_14102019.pdf>. Access in: march 2020.

RAMSAY, James O; SILVERMAN, Bernard W. **Applied functional data analysis: methods and case studies**. [S.l.]: Springer, 2007.

RAY, Partha Pratim. A survey on internet of things architectures. **Journal of King Saud University-Computer and Information Sciences**, Elsevier, v. 30, n. 3, p. 291–319, 2018.

RICHARDSON, Matt; WALLACE, Shawn. **Getting started with raspberry PI**. [S.l.]: "O'Reilly Media, Inc.", 2012.

RIGHI, Rodrigo da Rosa et al. Autoelastic: Automatic resource elasticity for high performance applications in the cloud. **IEEE Transactions on Cloud Computing**, IEEE, v. 4, n. 1, p. 6–19, 2015.

RUGGERO, Federica; GORI, Riccardo; LUBELLO, Claudio. Methodologies to assess biodegradation of bioplastics during aerobic composting and anaerobic digestion: A review. **Waste Management & Research**, SAGE Publications Sage UK: London, England, v. 37, n. 10, p. 959–975, 2019.

SAIGAL, S; MEHROTRA, D. Performance comparison of time series data using predictive data mining techniques. **Advances in Information Mining**, v. 4, n. 1, p. 57–66, 2012.

SARLE, Warren S. *Neural networks and statistical models*. Citeseer, 1994.

SETHI, Pallavi; SARANGI, Smruti R. Internet of things: architectures, protocols, and applications. **Journal of Electrical and Computer Engineering**, Hindawi, v. 2017, 2017.

SHANTHAMALLU, Uday Shankar et al. A brief survey of machine learning methods and their sensor and iot applications. In: IEEE. **2017 8th International Conference on Information, Intelligence, Systems & Applications (IISA)**. [S.l.], 2017. p. 1–8.

SHCHERBAKOV, Maxim Vladimirovich et al. A survey of forecast error measures. **World Applied Sciences Journal**, Citeseer, v. 24, n. 24, p. 171–176, 2013.

SILVEIRA, Ana et al. A method for the rapid evaluation of leather biodegradability during the production phase. **Waste management**, Elsevier, v. 87, p. 661–671, 2019.

SINGH, Kiran Jot; KAPOOR, Divneet Singh. Create your own internet of things: A survey of iot platforms. **IEEE Consumer Electronics Magazine**, IEEE, v. 6, n. 2, p. 57–68, 2017.

SOIBELMAN, Lucio; KIM, Hyunjoo. Data preparation process for construction knowledge generation through knowledge discovery in databases. **Journal of Computing in Civil Engineering**, American Society of Civil Engineers, v. 16, n. 1, p. 39–48, 2002.

SUTSKEVER, Ilya; VINYALS, Oriol; LE, Quoc V. Sequence to sequence learning with neural networks. In: **Advances in neural information processing systems**. [S.l.: s.n.], 2014. p. 3104–3112.

SUTTON, Richard S; BARTO, Andrew G. *Reinforcement learning: An introduction*. Cambridge, MA: MIT Press, 2011.

TAYLOR, Richard. Interpretation of the correlation coefficient: a basic review. **Journal of diagnostic medical sonography**, Sage Publications Sage CA: Thousand Oaks, CA, v. 6, n. 1, p. 35–39, 1990.

TEALAB, Ahmed. Time series forecasting using artificial neural networks methodologies: A systematic review. **Future Computing and Informatics Journal**, Elsevier, v. 3, n. 2, p. 334–340, 2018.

TURING, Alan M. Computing machinery and intelligence. In: **Parsing the Turing Test**. [S.l.]: Springer, 2009. p. 23–65.

VARGAS, Alejandro; MORENO, J Carlos; MENDOZA, Ismael. Development of an automated anaerobic biodegradability testing device. **Instrumentation Science and Technology**, Taylor & Francis, v. 37, n. 1, p. 40–49, 2009.

VERMESAN, Ovidiu et al. Internet of robotic things: converging sensing/actuating, hypoconnectivity, artificial intelligence and iot platforms. River Publishers, 2017.

VOYANT, Cyril et al. Machine learning methods for solar radiation forecasting: A review. **Renewable Energy**, Elsevier, v. 105, p. 569–582, 2017.

WALPOLE, Ronald E. **Probabilidade & Estatística para engenharia e ciências**. [S.l.]: Pearson Prentice Hall, 2009.

WASSERMAN, Larry. **All of statistics: a concise course in statistical inference**. [S.l.]: Springer Science & Business Media, 2013.

Weka - The workbench for machine learning. **Weka**. 2020. Disponível em: <<https://waikato.github.io/weka-wiki/documentation/>>. Access in: may 2020.

Wolfram Alpha - Computational Intelligence. **Wolfram Alpha**. 2020. Disponível em: <<https://www.wolframalpha.com/>>. Access in: may 2020.

WOLLSCHLAEGER, Martin; SAUTER, Thilo; JASPERNEITE, Juergen. The future of industrial communication: Automation networks in the era of the internet of things and industry 4.0. **IEEE industrial electronics magazine**, IEEE, v. 11, n. 1, p. 17–27, 2017.

XU, Li Da; DUAN, Lian. Big data for cyber physical systems in industry 4.0: A survey. **Enterprise Information Systems**, Taylor & Francis, v. 13, n. 2, p. 148–169, 2019.

XUE, Ming; ZHU, Changjun. A study and application on machine learning of artificial intelligence. In: IEEE. **2009 International Joint Conference on Artificial Intelligence**. [S.l.], 2009. p. 272–274.

YAN, Zheng; ZHANG, Peng; VASILAKOS, Athanasios V. A survey on trust management for internet of things. **Journal of network and computer applications**, Elsevier, v. 42, p. 120–134, 2014.

YAQOOB, Ibrar et al. Internet of things architecture: Recent advances, taxonomy, requirements, and open challenges. **IEEE wireless communications**, IEEE, v. 24, n. 3, p. 10–16, 2017.

YIN, Guang-Zhong; YANG, Xiao-Mei. Biodegradable polymers: a cure for the planet, but a long way to go. **Journal of Polymer Research**, Springer, v. 27, n. 2, p. 38, 2020.

ZHANG, G Peter. Time series forecasting using a hybrid arima and neural network model. **Neurocomputing**, Elsevier, v. 50, p. 159–175, 2003.

ZHANG, Shichao; ZHANG, Chengqi; YANG, Qiang. Data preparation for data mining. **Applied artificial intelligence**, Taylor & Francis, v. 17, n. 5-6, p. 375–381, 2003.

ZHAO, Quanxin. Presents the technology, protocols, and new innovations in industrial internet of things (iiot). In: **Internet of Things for Industry 4.0**. [S.l.]: Springer, 2020. p. 39–56.

ANEXO A

Figura 56: Certificado do gás padrão utilizado para calibração dos sensores de gás




RELATÓRIO TÉCNICO DE GARANTIA DA QUALIDADE

Certificado : 27.700

Cliente: SERVIÇO NACIONAL DE APRENDIZAGEM INDUSTRIAL
Endereço: Av. Presidente João Goulart, 682 - São Leopoldo / RS

Produto: Padrão Primário
Pedido: 201/19
Centro Vendas: 201
Tipo cilindro: B-10/ 10 l
Volume: 1,00 m3 a 21°C a 101,3 kPa
Método de Confeção: Gravimétrico

Conexão da Válvula: ABNT 218-2 / DIN 477-1
Cilindro nº : 10.195.361
Pressão: 100 bar ou 10.000 kpa
Data Validade: 22/11/2024
Data confecção: 19/11/2019

Composição:

Componentes	Requisitado	Reportado	Incerteza de medição	Método de verificação	Data
Dióxido de Carbono	0,300 %mol/mol	0,294 %mol/mol	+/- 0,006 %mol/mol	Cromatografia CG / TCD	22/11/2019
Metano	0,300 %mol/mol	0,309 %mol/mol	+/- 0,006 %mol/mol	Cromatografia CG / TCD	22/11/2019
Nitrogênio	Q.S.				

Rastreabilidade:
Este padrão foi produzido em unidade industrial com gestão certificada pelo sistema da qualidade ISO 9001:2015, certificado ABS Quality Evaluations nº 38782.
O material foi fabricado ou transferido gravimetricamente em comparadoras de massa rastreáveis à RBC – Rede Brasileira de Calibração conforme certificados de calibração: BA 018_03_19, BA 019_03_19, LAB 19214303, LAB 19214304, certificado de aferição de massas padrão MA 459_03_19. A aferição das massas padrões foram realizadas por empresa pertencente à RBC com certificado CAL 0291.

Incerteza
A incerteza expandida declarada está baseada na incerteza padrão combinada multiplicada pelo fator de abrangência k=2 que representa um nível de confiança de 95%.

Temperatura de armazenagem/uso:
A estabilidade estará garantida, desde que o cilindro seja armazenado em local ventilado, ao abrigo de intempéries e entre as temperaturas de 0 °C a 45 °C.
Pressão ou massa residual recomendada: 2% da pressão ou massa do valor reportado.

Equivalência unidades

% - %mol/mol

ppm - micromol/mol

ppb - nanomol/mol

Date: 29/11/19

Ricardo Sanches Cabral

RICARDO SANCHES CABRAL

Responsável Técnico

CRQ 04428558 - 4ª Região

Os resultados apresentados neste documento referem-se exclusivamente a amostra analisada. A reprodução deste documento só poderá ser total e depende da aprovação escrita do laboratório.

Pag: 1 de 1

Air Liquide Brasil Ltda.
Av. Presidente Wilson, 5874 CEP 04220-002 São Paulo
Tel:(11)2948-9873 E-mail:producao.alphagaz@airliquide.com.br
PPT UPAG 21.002 FR13 Rev 15

ANEXO B

Figura 57: Tabela t de Student

Tabela 6.1 - Tabela de Student (para curvas simétricas)

Graus de liberdade $v = n - 1$	t90%	t95%	t99%
	$\alpha/2 = 0,05$	$\alpha/2 = 0,025$	$\alpha/2 = 0,01$
1	6,314	12,706	63,657
2	2,920	4,303	9,925
3	2,353	3,128	5,841
4	2,132	2,770	4,604
5	2,015	2,571	4,032
6	1,943	2,447	3,707
7	1,895	2,365	3,499
8	1,860	2,306	3,355
9	1,833	2,262	3,250
10	1,812	2,228	3,169
11	1,796	2,201	3,106
12	1,782	2,179	3,005
13	1,771	2,160	3,012
14	1,761	2,145	2,977
15	1,753	2,131	2,947
16	1,746	2,120	2,921
17	1,740	2,110	2,898
18	1,734	2,101	2,878
19	1,729	2,093	2,861
20	1,725	2,086	2,845
21	1,721	2,080	2,831
22	1,717	2,074	2,819
23	1,714	2,069	2,807
24	1,711	2,064	2,797
25	1,708	2,060	2,787
30	1,697	2,042	2,750
40	1,684	2,021	2,704
60	1,671	2,000	2,660
120	1,658	1,980	2,617
∞	1,645	1,960	2,576

ANEXO C

Figura 58: Planilha de calibração do Cromatógrafo

Medições			
Medida	Padrão	Instrumento	Erro
1	2940	2699	-241,0000
2	2940	2699	-241,0000
3	2940	2699	-241,0000
4	2940	2710	-230,0000
5	2940	2710	-230,0000
6	2940	2710	-230,0000
7	2940	2710	-230,0000
8	2940	2710	-230,0000
9	2940	2710	-230,0000
10	2940	2710	-230,0000
11	2940	2710	-230,0000
12	2940	2710	-230,0000
13	2940	2710	-230,0000
14	2940	2710	-230,0000
15	2940	2710	-230,0000
16	2940	2708	-232,0000
17	2940	2708	-232,0000
18	2940	2708	-232,0000
19	2940	2708	-232,0000
20	2940	2708	-232,0000
21	2940	2708	-232,0000
22	2940	2708	-232,0000
23	2940	2708	-232,0000
24	2940	2708	-232,0000
25	2940	2708	-232,0000
26	2940	2708	-232,0000
27	2940	2708	-232,0000
28	2940	2661	-279,0000
29	2940	2661	-279,0000
30	2940	2661	-279,0000
31	2940	2661	-279,0000

Média do erro	
	-238,1613
Média	2701,8387
Variancia	265,0065
Desvio Pad.	16,2790
Número de medidas	31

Dados Padrão	
U	60
K	2
U conf. Resolução	
1	

Incertezas						
	Xi	Tipo	Distribuição	Divisor	U	GI
Padrão	2701,8387	A	Normal	1	2,97213	30
Calibração	-	B	Normal	1	30	infinito
Resolução	-	B	Retangular	1,73205	0,28868	infinito

UC	30,1482484
Veff	317613,6874
K 95%	1,96

Erro do padrão:	238,1613
-----------------	----------

Valor Real:	2701,8387	± 59,0906
Maior Valor:	2760,9293	Menor Valor: 2642,7481

$$u_i = \sqrt{u_1^2 + u_2^2 + u_3^2 + \dots + u_n^2}$$

$$V_{eff} = \frac{U_c^2(y)}{\sum \frac{U_i^2}{v_i}}$$

Normal -> $u(y) = \frac{s(y)}{\sqrt{m}}$

Retangular -> $U_{res} = \frac{Res}{\sqrt{3}}$

Valor Real (média + erro)
2940,0000

Variação (U)
59,09056687

U = k · Uc

ANEXO D

Figura 59: Planilha de calibração Sensor Mhz-14a

Mhz-14a					
Médições		<table border="1" style="width: 100%;"> <tr> <td>Média do erro</td> <td>-237,4516</td> </tr> </table>		Média do erro	-237,4516
Média do erro	-237,4516				
Medida	Padrão	Instrumento	Erro		
1	2940	2718	-222,0000		
2	2940	2708	-232,0000		
3	2940	2711	-229,0000		
4	2940	2710	-230,0000		
5	2940	2716	-224,0000		
6	2940	2721	-219,0000		
7	2940	2716	-224,0000		
8	2940	2708	-232,0000		
9	2940	2713	-227,0000		
10	2940	2716	-224,0000		
11	2940	2716	-224,0000		
12	2940	2711	-229,0000		
13	2940	2711	-229,0000		
14	2940	2708	-232,0000		
15	2940	2706	-234,0000		
16	2940	2703	-237,0000		
17	2940	2700	-240,0000		
18	2940	2703	-237,0000		
19	2940	2708	-232,0000		
20	2940	2706	-234,0000		
21	2940	2700	-240,0000		
22	2940	2700	-240,0000		
23	2940	2703	-237,0000		
24	2940	2693	-247,0000		
25	2940	2693	-247,0000		
26	2940	2685	-255,0000		
27	2940	2682	-258,0000		
28	2940	2675	-265,0000		
29	2940	2675	-265,0000		
30	2940	2682	-258,0000		
31	2940	2682	-258,0000		

Média	2702,5484
Variância	170,6559
Desvio Pad.	13,0635
Número de medidas	31

Dados Padrão	
U	K
60	2
U conf. Resolução	
1	

Incertezas						
	Xi	Tipo	Distribuição	Divisor	U	Gi
Padrão	2702,5484	A	Normal	1	2,38506	30
Calibração	-	B	Normal	1	30	infinito
Resolução	-	B	Retangular	1,73205	0,28868	infinito

Normal -> $u(y) = \frac{s(y)}{\sqrt{m}}$

Retangular -> $U_{res} = \frac{Res}{\sqrt{3}}$

UC	30,09604399
Veff	760604,2187
K 95%	1,96

$$u_c = \sqrt{u_1^2 + u_2^2 + u_3^2 + \dots + u_n^2}$$

$$V_{eff} = \frac{Uc^4(y)}{\sum \frac{1}{v_i}}$$

Valor Real (média + erro) 2940,0000 Variação (U) 58,98824622 $U = k \cdot Uc$

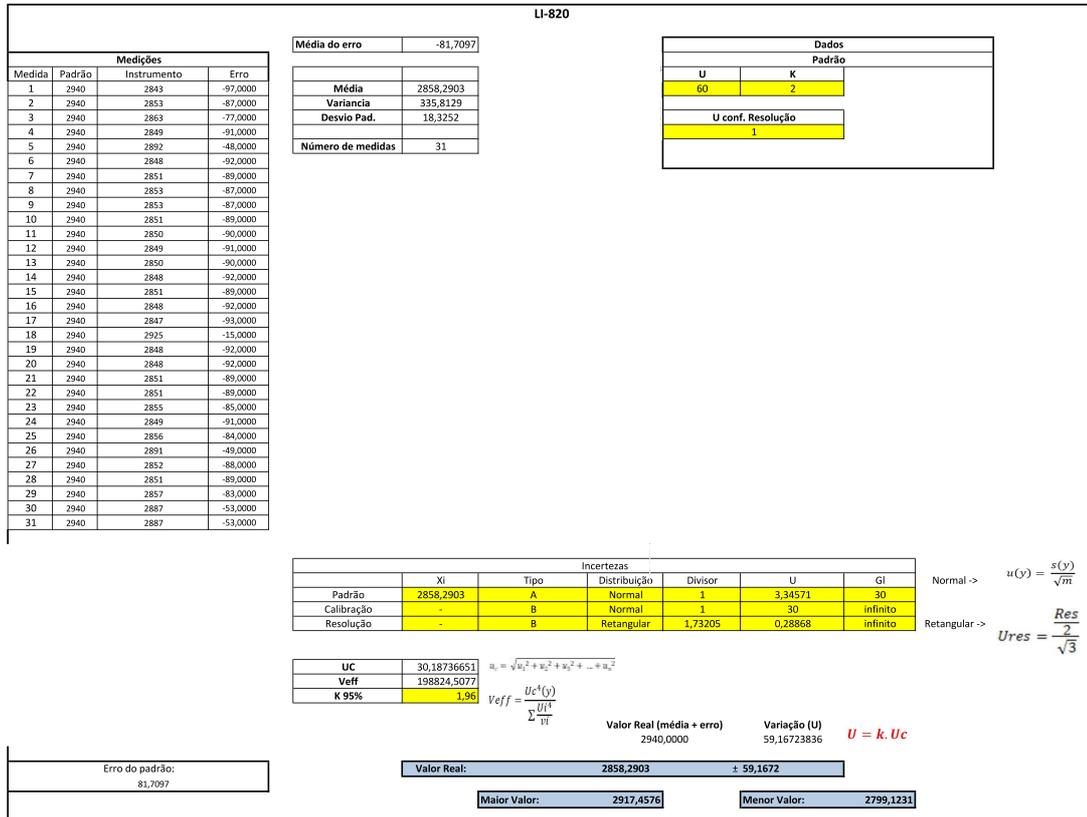
Erro do padrão: 237,4516

Valor Real:	2702,5484	± 58,9882
-------------	-----------	-----------

Maior Valor:	2761,5366	Menor Valor:	2643,5601
--------------	-----------	--------------	-----------

ANEXO E

Figura 60: Planilha de calibração Sensor LI-820



ANEXO F

Figura 61: Planilha de calibração Sensor MQ-135

Medições			
Medida	Padrão	Instrumento	Erro
1	2940	745	-2195,0000
2	2940	748	-2192,0000
3	2940	745	-2195,0000
4	2940	751	-2189,0000
5	2940	753	-2187,0000
6	2940	758	-2182,0000
7	2940	756	-2184,0000
8	2940	749	-2191,0000
9	2940	766	-2174,0000
10	2940	761	-2179,0000
11	2940	767	-2173,0000
12	2940	770	-2170,0000
13	2940	771	-2169,0000
14	2940	770	-2170,0000
15	2940	771	-2169,0000
16	2940	771	-2169,0000
17	2940	767	-2173,0000
18	2940	771	-2169,0000
19	2940	779	-2161,0000
20	2940	795	-2145,0000
21	2940	782	-2158,0000
22	2940	783	-2157,0000
23	2940	780	-2160,0000
24	2940	781	-2159,0000
25	2940	805	-2135,0000
26	2940	786	-2154,0000
27	2940	786	-2154,0000
28	2940	787	-2153,0000
29	2940	787	-2153,0000
30	2940	792	-2148,0000
31	2940	784	-2156,0000

Média do erro	
Média do erro	-2168,4839

Dados Padrão	
U	K
60	2
U conf. Resolução	
1	

Incertezas						
	Xi	Tipo	Distribuição	Divisor	U	Gi
Padrão	771,5161	A	Normal	1	2,87668	30
Calibração	-	B	Normal	1	30	infinito
Resolução	-	B	Retangular	1,73205	0,28868	infinito

UC	30,13898807	$u_i = \sqrt{u_1^2 + u_2^2 + u_3^2 + \dots + u_n^2}$ $U_{eff} = \frac{U_c^c(y)}{\sum \frac{U_i^c}{v_i}}$
VeH	361489,535	
K 95%	1,96	

Valor Real (média + erro)	2940,0000	Varição (U)	59,07241663	$U = k \cdot U_c$	
Valor Real:	771,5161	±	59,0724		
Maior Valor:	830,5885			Menor Valor:	712,4437

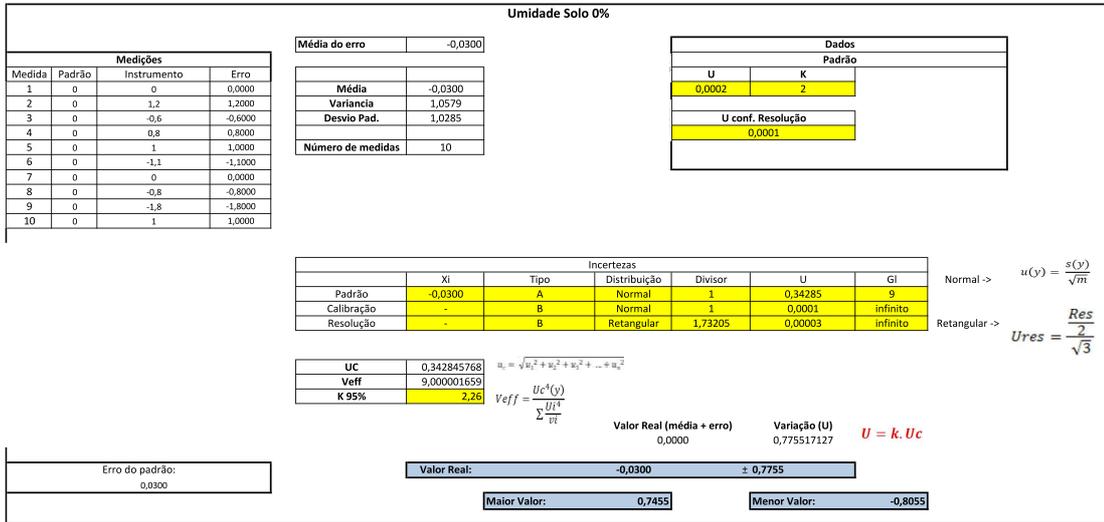
Erro do padrão:	2168,4839
-----------------	-----------

Normal -> $u(y) = \frac{s(y)}{\sqrt{m}}$

Retangular -> $U_{res} = \frac{Res}{\sqrt{3}}$

ANEXO G

Figura 62: Planilha de calibração Sensor Umidade do Solo 0%



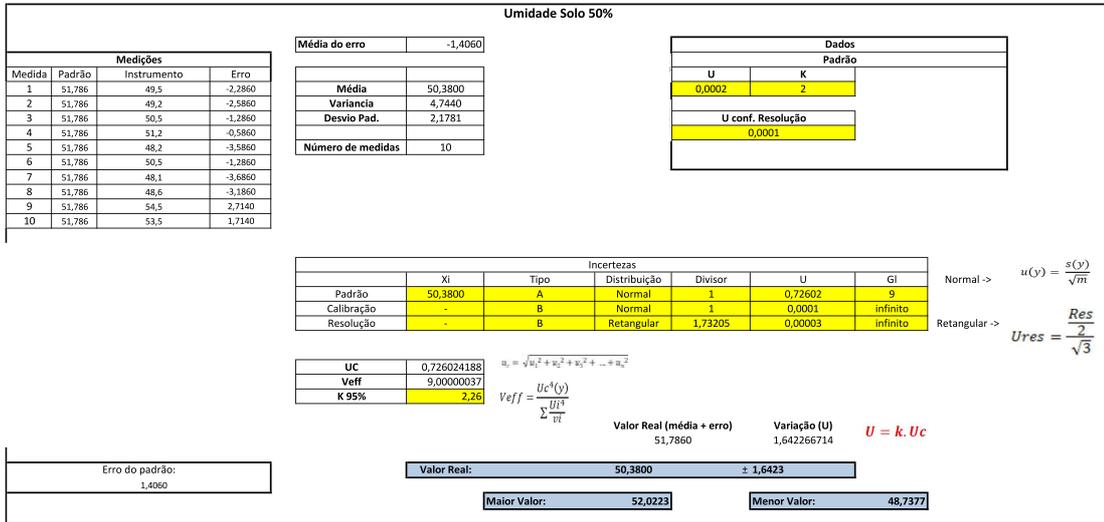
ANEXO H

Figura 63: Planilha de calibração Sensor Umidade do Solo 20%

Umidade Solo 20%																																																			
<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="4" style="text-align: center;">Médias</th> </tr> <tr> <th>Medida</th> <th>Padrão</th> <th>Instrumento</th> <th>Erro</th> </tr> </thead> <tbody> <tr><td>1</td><td>21,521</td><td>20,8</td><td>-0,7210</td></tr> <tr><td>2</td><td>21,521</td><td>19,1</td><td>-2,4210</td></tr> <tr><td>3</td><td>21,521</td><td>20,3</td><td>-1,2210</td></tr> <tr><td>4</td><td>21,521</td><td>20,4</td><td>-1,1210</td></tr> <tr><td>5</td><td>21,521</td><td>21,2</td><td>-0,3210</td></tr> <tr><td>6</td><td>21,521</td><td>18,9</td><td>-2,6210</td></tr> <tr><td>7</td><td>21,521</td><td>20,5</td><td>-1,0210</td></tr> <tr><td>8</td><td>21,521</td><td>20</td><td>-1,5210</td></tr> <tr><td>9</td><td>21,521</td><td>19,5</td><td>-2,0210</td></tr> <tr><td>10</td><td>21,521</td><td>19,6</td><td>-1,9210</td></tr> </tbody> </table>				Médias				Medida	Padrão	Instrumento	Erro	1	21,521	20,8	-0,7210	2	21,521	19,1	-2,4210	3	21,521	20,3	-1,2210	4	21,521	20,4	-1,1210	5	21,521	21,2	-0,3210	6	21,521	18,9	-2,6210	7	21,521	20,5	-1,0210	8	21,521	20	-1,5210	9	21,521	19,5	-2,0210	10	21,521	19,6	-1,9210
Médias																																																			
Medida	Padrão	Instrumento	Erro																																																
1	21,521	20,8	-0,7210																																																
2	21,521	19,1	-2,4210																																																
3	21,521	20,3	-1,2210																																																
4	21,521	20,4	-1,1210																																																
5	21,521	21,2	-0,3210																																																
6	21,521	18,9	-2,6210																																																
7	21,521	20,5	-1,0210																																																
8	21,521	20	-1,5210																																																
9	21,521	19,5	-2,0210																																																
10	21,521	19,6	-1,9210																																																
<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="2" style="text-align: center;">Média do erro</th> </tr> </thead> <tbody> <tr> <td></td> <td style="text-align: center;">-1,4910</td> </tr> </tbody> </table>				Média do erro			-1,4910																																												
Média do erro																																																			
	-1,4910																																																		
<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="2" style="text-align: center;">Dados Padrão</th> </tr> </thead> <tbody> <tr> <td style="text-align: center;">U</td> <td style="text-align: center;">K</td> </tr> <tr> <td style="text-align: center;">0,0002</td> <td style="text-align: center;">2</td> </tr> <tr> <td colspan="2" style="text-align: center;">U conf. Resolução</td> </tr> <tr> <td colspan="2" style="text-align: center;">0,0001</td> </tr> </tbody> </table>				Dados Padrão		U	K	0,0002	2	U conf. Resolução		0,0001																																							
Dados Padrão																																																			
U	K																																																		
0,0002	2																																																		
U conf. Resolução																																																			
0,0001																																																			
<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="6" style="text-align: center;">Incertezas</th> </tr> <tr> <th></th> <th>Xi</th> <th>Tipo</th> <th>Distribuição</th> <th>Divisor</th> <th>U</th> <th>GI</th> </tr> </thead> <tbody> <tr> <td>Padrão</td> <td style="text-align: center;">20,0300</td> <td style="text-align: center;">A</td> <td style="text-align: center;">Normal</td> <td style="text-align: center;">1</td> <td style="text-align: center;">0,24848</td> <td style="text-align: center;">9</td> </tr> <tr> <td>Calibração</td> <td style="text-align: center;">-</td> <td style="text-align: center;">B</td> <td style="text-align: center;">Normal</td> <td style="text-align: center;">1</td> <td style="text-align: center;">0,0001</td> <td style="text-align: center;">infinito</td> </tr> <tr> <td>Resolução</td> <td style="text-align: center;">-</td> <td style="text-align: center;">B</td> <td style="text-align: center;">Retangular</td> <td style="text-align: center;">1,73205</td> <td style="text-align: center;">0,00003</td> <td style="text-align: center;">infinito</td> </tr> </tbody> </table>				Incertezas							Xi	Tipo	Distribuição	Divisor	U	GI	Padrão	20,0300	A	Normal	1	0,24848	9	Calibração	-	B	Normal	1	0,0001	infinito	Resolução	-	B	Retangular	1,73205	0,00003	infinito														
Incertezas																																																			
	Xi	Tipo	Distribuição	Divisor	U	GI																																													
Padrão	20,0300	A	Normal	1	0,24848	9																																													
Calibração	-	B	Normal	1	0,0001	infinito																																													
Resolução	-	B	Retangular	1,73205	0,00003	infinito																																													
<table border="1" style="width: 100%; border-collapse: collapse;"> <tbody> <tr> <td style="text-align: center;">UC</td> <td style="text-align: center;">0,248476863</td> </tr> <tr> <td style="text-align: center;">Veff</td> <td style="text-align: center;">9,000003158</td> </tr> <tr> <td style="text-align: center;">K 95%</td> <td style="text-align: center;">2,26</td> </tr> </tbody> </table>				UC	0,248476863	Veff	9,000003158	K 95%	2,26																																										
UC	0,248476863																																																		
Veff	9,000003158																																																		
K 95%	2,26																																																		
<p style="text-align: center;"> $u_i = \sqrt{u_1^2 + u_2^2 + u_3^2 + \dots + u_n^2}$ $V_{eff} = \frac{U_c^4(y)}{\sum \frac{U_i^4}{V_i}}$ </p>																																																			
<table style="width: 100%;"> <tr> <td style="text-align: center;"> <table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="2" style="text-align: center;">Erro do padrão:</th> </tr> </thead> <tbody> <tr> <td></td> <td style="text-align: center;">1,4910</td> </tr> </tbody> </table> </td> <td style="text-align: center;"> <table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="2" style="text-align: center;">Valor Real (média + erro)</th> </tr> </thead> <tbody> <tr> <td style="text-align: center;">21,5210</td> <td style="text-align: center;">± 0,5621</td> </tr> </tbody> </table> </td> <td style="text-align: center;"> <table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="2" style="text-align: center;">Variação (U)</th> </tr> </thead> <tbody> <tr> <td style="text-align: center;">0,562054665</td> <td style="text-align: center;">U = k · UC</td> </tr> </tbody> </table> </td> </tr> </table>				<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="2" style="text-align: center;">Erro do padrão:</th> </tr> </thead> <tbody> <tr> <td></td> <td style="text-align: center;">1,4910</td> </tr> </tbody> </table>	Erro do padrão:			1,4910	<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="2" style="text-align: center;">Valor Real (média + erro)</th> </tr> </thead> <tbody> <tr> <td style="text-align: center;">21,5210</td> <td style="text-align: center;">± 0,5621</td> </tr> </tbody> </table>	Valor Real (média + erro)		21,5210	± 0,5621	<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="2" style="text-align: center;">Variação (U)</th> </tr> </thead> <tbody> <tr> <td style="text-align: center;">0,562054665</td> <td style="text-align: center;">U = k · UC</td> </tr> </tbody> </table>	Variação (U)		0,562054665	U = k · UC																																	
<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="2" style="text-align: center;">Erro do padrão:</th> </tr> </thead> <tbody> <tr> <td></td> <td style="text-align: center;">1,4910</td> </tr> </tbody> </table>	Erro do padrão:			1,4910	<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="2" style="text-align: center;">Valor Real (média + erro)</th> </tr> </thead> <tbody> <tr> <td style="text-align: center;">21,5210</td> <td style="text-align: center;">± 0,5621</td> </tr> </tbody> </table>	Valor Real (média + erro)		21,5210	± 0,5621	<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="2" style="text-align: center;">Variação (U)</th> </tr> </thead> <tbody> <tr> <td style="text-align: center;">0,562054665</td> <td style="text-align: center;">U = k · UC</td> </tr> </tbody> </table>	Variação (U)		0,562054665	U = k · UC																																					
Erro do padrão:																																																			
	1,4910																																																		
Valor Real (média + erro)																																																			
21,5210	± 0,5621																																																		
Variação (U)																																																			
0,562054665	U = k · UC																																																		
<table style="width: 100%;"> <tr> <td style="text-align: center;"> <table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="2" style="text-align: center;">Valor Real:</th> </tr> </thead> <tbody> <tr> <td style="text-align: center;">20,0300</td> <td style="text-align: center;">± 0,5621</td> </tr> </tbody> </table> </td> <td style="text-align: center;"> <table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="2" style="text-align: center;">Maior Valor:</th> </tr> </thead> <tbody> <tr> <td style="text-align: center;">20,5921</td> <td style="text-align: center;">Menor Valor: 19,4679</td> </tr> </tbody> </table> </td> </tr> </table>				<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="2" style="text-align: center;">Valor Real:</th> </tr> </thead> <tbody> <tr> <td style="text-align: center;">20,0300</td> <td style="text-align: center;">± 0,5621</td> </tr> </tbody> </table>	Valor Real:		20,0300	± 0,5621	<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="2" style="text-align: center;">Maior Valor:</th> </tr> </thead> <tbody> <tr> <td style="text-align: center;">20,5921</td> <td style="text-align: center;">Menor Valor: 19,4679</td> </tr> </tbody> </table>	Maior Valor:		20,5921	Menor Valor: 19,4679																																						
<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="2" style="text-align: center;">Valor Real:</th> </tr> </thead> <tbody> <tr> <td style="text-align: center;">20,0300</td> <td style="text-align: center;">± 0,5621</td> </tr> </tbody> </table>	Valor Real:		20,0300	± 0,5621	<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="2" style="text-align: center;">Maior Valor:</th> </tr> </thead> <tbody> <tr> <td style="text-align: center;">20,5921</td> <td style="text-align: center;">Menor Valor: 19,4679</td> </tr> </tbody> </table>	Maior Valor:		20,5921	Menor Valor: 19,4679																																										
Valor Real:																																																			
20,0300	± 0,5621																																																		
Maior Valor:																																																			
20,5921	Menor Valor: 19,4679																																																		
<p style="text-align: right;"> Normal -> $u(y) = \frac{s(y)}{\sqrt{m}}$ Retangular -> $U_{res} = \frac{Res}{\sqrt{3}}$ </p>																																																			

ANEXO I

Figura 64: Planilha de calibração Sensor Umidade do Solo 50%



ANEXO J

Figura 65: Planilha de calibração Sensor Umidade do Solo 100%

Umidade Solo 100%					
Méda do erro -0,3500					
Dados					
U		K			
0,0002		2			
U conf. Resolução					
0,0001					
Méda do erro -0,3500					
Méda 99,6500					
Variância 0,2717					
Desvio Pad. 0,5212					
Número de medidas 10					
Medições					
Medida	Padrão	Instrumento	Erro		
1	100	100	0,0000		
2	100	99,5	-0,5000		
3	100	100	0,0000		
4	100	99	-1,0000		
5	100	100	0,0000		
6	100	98,5	-1,5000		
7	100	100	0,0000		
8	100	99,6	-0,4000		
9	100	99,9	-0,1000		
10	100	100	0,0000		
Incertezas					
Xi	Tipo	Distribuição	Divisor	U	Gi
Padrão	K	Normal	1	0,17374	9
Calibração	B	Normal	1	0,0001	infinito
Resolução	B	Retangular	1,73205	0,00003	infinito
$u_i = \sqrt{u_1^2 + u_2^2 + u_3^2 + \dots + u_n^2}$					
$U_{eff} = \frac{U_c(y)}{\sqrt{1 + \frac{U_c^2}{U^2}}}$					
UC	0,173738873				
Veff	9,00000646				
K 95%	2,26				
Normal -> $u(y) = \frac{s(y)}{\sqrt{m}}$					
Retangular -> $U_{res} = \frac{Res}{\sqrt{3}}$					
Valor Real (média + erro) 100,0000 Varição (U) 0,392997331 U = k · Uc					
Valor Real: 99,6500 ± 0,3930					
Maior Valor: 100,0430 Menor Valor: 99,2570					
Erro do padrão: 0,3500					

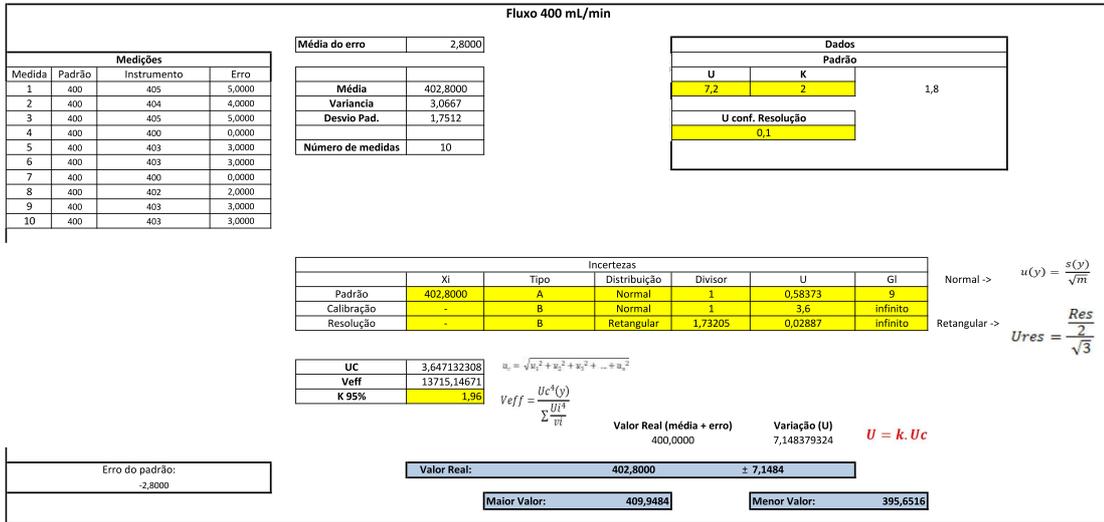
ANEXO K

Figura 66: Planilha de calibração Sensor de Fluxo 100 mL/min

Fluxo 100 mL/min																																																			
<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="4">Médias</th> </tr> <tr> <th>Medida</th> <th>Padrão</th> <th>Instrumento</th> <th>Erro</th> </tr> </thead> <tbody> <tr><td>1</td><td>100</td><td>102</td><td>2,0000</td></tr> <tr><td>2</td><td>100</td><td>104</td><td>4,0000</td></tr> <tr><td>3</td><td>100</td><td>99</td><td>-1,0000</td></tr> <tr><td>4</td><td>100</td><td>102</td><td>2,0000</td></tr> <tr><td>5</td><td>100</td><td>100</td><td>0,0000</td></tr> <tr><td>6</td><td>100</td><td>102</td><td>2,0000</td></tr> <tr><td>7</td><td>100</td><td>99</td><td>-1,0000</td></tr> <tr><td>8</td><td>100</td><td>99</td><td>-1,0000</td></tr> <tr><td>9</td><td>100</td><td>100</td><td>0,0000</td></tr> <tr><td>10</td><td>100</td><td>101</td><td>1,0000</td></tr> </tbody> </table>				Médias				Medida	Padrão	Instrumento	Erro	1	100	102	2,0000	2	100	104	4,0000	3	100	99	-1,0000	4	100	102	2,0000	5	100	100	0,0000	6	100	102	2,0000	7	100	99	-1,0000	8	100	99	-1,0000	9	100	100	0,0000	10	100	101	1,0000
Médias																																																			
Medida	Padrão	Instrumento	Erro																																																
1	100	102	2,0000																																																
2	100	104	4,0000																																																
3	100	99	-1,0000																																																
4	100	102	2,0000																																																
5	100	100	0,0000																																																
6	100	102	2,0000																																																
7	100	99	-1,0000																																																
8	100	99	-1,0000																																																
9	100	100	0,0000																																																
10	100	101	1,0000																																																
<table border="1" style="width: 100%; border-collapse: collapse;"> <tr><td>Média do erro</td><td>0,8000</td></tr> <tr><td>Média</td><td>100,8000</td></tr> <tr><td>Variância</td><td>2,8444</td></tr> <tr><td>Desvio Pad.</td><td>1,6865</td></tr> <tr><td>Número de medidas</td><td>10</td></tr> </table>		Média do erro	0,8000	Média	100,8000	Variância	2,8444	Desvio Pad.	1,6865	Número de medidas	10	<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="2">Dados Padrão</th> <th rowspan="2">1,8</th> </tr> <tr> <th>U</th> <th>K</th> </tr> </thead> <tbody> <tr> <td>1,8</td> <td>2</td> <td></td> </tr> <tr> <th colspan="2">U conf. Resolução</th> <td></td> </tr> <tr> <td colspan="2">0,1</td> <td></td> </tr> </tbody> </table>		Dados Padrão		1,8	U	K	1,8	2		U conf. Resolução			0,1																										
Média do erro	0,8000																																																		
Média	100,8000																																																		
Variância	2,8444																																																		
Desvio Pad.	1,6865																																																		
Número de medidas	10																																																		
Dados Padrão		1,8																																																	
U	K																																																		
1,8	2																																																		
U conf. Resolução																																																			
0,1																																																			
<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="6">Incertezas</th> </tr> <tr> <th></th> <th>Xi</th> <th>Tipo</th> <th>Distribuição</th> <th>Divisor</th> <th>U</th> <th>GI</th> </tr> </thead> <tbody> <tr> <td>Padrão</td> <td>100,8000</td> <td>A</td> <td>Normal</td> <td>1</td> <td>0,56218</td> <td>9</td> </tr> <tr> <td>Calibração</td> <td>-</td> <td>B</td> <td>Normal</td> <td>1</td> <td>0,9</td> <td>infinito</td> </tr> <tr> <td>Resolução</td> <td>-</td> <td>B</td> <td>Retangular</td> <td>1,73205</td> <td>0,02887</td> <td>infinito</td> </tr> </tbody> </table>				Incertezas							Xi	Tipo	Distribuição	Divisor	U	GI	Padrão	100,8000	A	Normal	1	0,56218	9	Calibração	-	B	Normal	1	0,9	infinito	Resolução	-	B	Retangular	1,73205	0,02887	infinito														
Incertezas																																																			
	Xi	Tipo	Distribuição	Divisor	U	GI																																													
Padrão	100,8000	A	Normal	1	0,56218	9																																													
Calibração	-	B	Normal	1	0,9	infinito																																													
Resolução	-	B	Retangular	1,73205	0,02887	infinito																																													
<table border="1" style="width: 100%; border-collapse: collapse;"> <tr><td>UC</td><td>1,061547322</td></tr> <tr><td>Veff</td><td>114,4168672</td></tr> <tr><td>K 95%</td><td>1,98</td></tr> </table>				UC	1,061547322	Veff	114,4168672	K 95%	1,98																																										
UC	1,061547322																																																		
Veff	114,4168672																																																		
K 95%	1,98																																																		
<p style="text-align: right;">Normal -> $u(y) = \frac{s(y)}{\sqrt{m}}$</p> <p style="text-align: right;">Retangular -> $U_{res} = \frac{Res}{\sqrt{3}}$</p>																																																			
<p style="text-align: center;">$u_i = \sqrt{u_1^2 + u_2^2 + u_3^2 + \dots + u_n^2}$</p> <p style="text-align: center;">$V_{eff} = \frac{Uc^2(y)}{\sum \frac{1}{v_i}}$</p>																																																			
<table style="width: 100%;"> <tr> <td style="text-align: center;">Valor Real (média + erro)</td> <td style="text-align: center;">Variação (U)</td> <td rowspan="2" style="text-align: center;">$U = k \cdot Uc$</td> </tr> <tr> <td style="text-align: center;">100,0000</td> <td style="text-align: center;">2,101863697</td> </tr> </table>				Valor Real (média + erro)	Variação (U)	$U = k \cdot Uc$	100,0000	2,101863697																																											
Valor Real (média + erro)	Variação (U)	$U = k \cdot Uc$																																																	
100,0000	2,101863697																																																		
<table border="1" style="width: 100%; border-collapse: collapse;"> <tr> <td style="width: 30%;">Valor Real:</td> <td style="width: 40%; text-align: center;">100,8000</td> <td style="width: 30%; text-align: center;">± 2,1019</td> </tr> <tr> <td> </td> <td style="text-align: center;">Maior Valor: 102,9019</td> <td style="text-align: center;">Menor Valor: 98,6981</td> </tr> </table>				Valor Real:	100,8000	± 2,1019		Maior Valor: 102,9019	Menor Valor: 98,6981																																										
Valor Real:	100,8000	± 2,1019																																																	
	Maior Valor: 102,9019	Menor Valor: 98,6981																																																	
<table border="1" style="width: 100%; border-collapse: collapse;"> <tr> <td style="width: 50%;">Erro do padrão:</td> <td style="width: 50%; text-align: center;">-0,8000</td> </tr> </table>				Erro do padrão:	-0,8000																																														
Erro do padrão:	-0,8000																																																		

ANEXO L

Figura 67: Planilha de calibração Sensor de Fluxo 400 mL/min



ANEXO M

Figura 68: Planilha de calibração Sensor de Fluxo 600 mL/min

Fluxo 600 mL/min																																																			
<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="4">Médias</th> </tr> <tr> <th>Medida</th> <th>Padrão</th> <th>Instrumento</th> <th>Erro</th> </tr> </thead> <tbody> <tr><td>1</td><td>600</td><td>603</td><td>3,0000</td></tr> <tr><td>2</td><td>600</td><td>602</td><td>2,0000</td></tr> <tr><td>3</td><td>600</td><td>605</td><td>5,0000</td></tr> <tr><td>4</td><td>600</td><td>603</td><td>3,0000</td></tr> <tr><td>5</td><td>600</td><td>602</td><td>2,0000</td></tr> <tr><td>6</td><td>600</td><td>605</td><td>5,0000</td></tr> <tr><td>7</td><td>600</td><td>605</td><td>5,0000</td></tr> <tr><td>8</td><td>600</td><td>604</td><td>4,0000</td></tr> <tr><td>9</td><td>600</td><td>605</td><td>5,0000</td></tr> <tr><td>10</td><td>600</td><td>603</td><td>3,0000</td></tr> </tbody> </table>				Médias				Medida	Padrão	Instrumento	Erro	1	600	603	3,0000	2	600	602	2,0000	3	600	605	5,0000	4	600	603	3,0000	5	600	602	2,0000	6	600	605	5,0000	7	600	605	5,0000	8	600	604	4,0000	9	600	605	5,0000	10	600	603	3,0000
Médias																																																			
Medida	Padrão	Instrumento	Erro																																																
1	600	603	3,0000																																																
2	600	602	2,0000																																																
3	600	605	5,0000																																																
4	600	603	3,0000																																																
5	600	602	2,0000																																																
6	600	605	5,0000																																																
7	600	605	5,0000																																																
8	600	604	4,0000																																																
9	600	605	5,0000																																																
10	600	603	3,0000																																																
<table border="1" style="width: 100%; border-collapse: collapse;"> <tr><td>Média do erro</td><td>3,7000</td></tr> <tr><td>Média</td><td>603,7000</td></tr> <tr><td>Variância</td><td>1,5667</td></tr> <tr><td>Desvio Pad.</td><td>1,2517</td></tr> <tr><td>Número de medidas</td><td>10</td></tr> </table>		Média do erro	3,7000	Média	603,7000	Variância	1,5667	Desvio Pad.	1,2517	Número de medidas	10	<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="2">Dados Padrão</th> <th rowspan="2">K</th> </tr> <tr> <th>U</th> <th>K</th> </tr> </thead> <tbody> <tr> <td>10,8</td> <td>2</td> <td>1,8</td> </tr> <tr> <th colspan="2">U conf. Resolução</th> <td></td> </tr> <tr> <td colspan="2">0,1</td> <td></td> </tr> </tbody> </table>		Dados Padrão		K	U	K	10,8	2	1,8	U conf. Resolução			0,1																										
Média do erro	3,7000																																																		
Média	603,7000																																																		
Variância	1,5667																																																		
Desvio Pad.	1,2517																																																		
Número de medidas	10																																																		
Dados Padrão		K																																																	
U	K																																																		
10,8	2	1,8																																																	
U conf. Resolução																																																			
0,1																																																			
<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="6">Incertezas</th> </tr> <tr> <th></th> <th>Xi</th> <th>Tipo</th> <th>Distribuição</th> <th>Divisor</th> <th>U</th> <th>GI</th> </tr> </thead> <tbody> <tr> <td>Padrão</td> <td>603,7000</td> <td>A</td> <td>Normal</td> <td>1</td> <td>0,41722</td> <td>9</td> </tr> <tr> <td>Calibração</td> <td>-</td> <td>B</td> <td>Normal</td> <td>1</td> <td>5,4</td> <td>infinito</td> </tr> <tr> <td>Resolução</td> <td>-</td> <td>B</td> <td>Retangular</td> <td>1,73205</td> <td>0,02887</td> <td>infinito</td> </tr> </tbody> </table>				Incertezas							Xi	Tipo	Distribuição	Divisor	U	GI	Padrão	603,7000	A	Normal	1	0,41722	9	Calibração	-	B	Normal	1	5,4	infinito	Resolução	-	B	Retangular	1,73205	0,02887	infinito														
Incertezas																																																			
	Xi	Tipo	Distribuição	Divisor	U	GI																																													
Padrão	603,7000	A	Normal	1	0,41722	9																																													
Calibração	-	B	Normal	1	5,4	infinito																																													
Resolução	-	B	Retangular	1,73205	0,02887	infinito																																													
<table border="1" style="width: 100%; border-collapse: collapse;"> <tr> <td>UC</td> <td>5,416170917</td> </tr> <tr> <td>Veff</td> <td>255589,9455</td> </tr> <tr> <td>K 95%</td> <td>1,96</td> </tr> </table>				UC	5,416170917	Veff	255589,9455	K 95%	1,96																																										
UC	5,416170917																																																		
Veff	255589,9455																																																		
K 95%	1,96																																																		
<p style="text-align: right;">Normal -> $u(y) = \frac{s(y)}{\sqrt{m}}$</p> <p style="text-align: right;">Retangular -> $U_{res} = \frac{Res}{\sqrt{3}}$</p>																																																			
<p style="text-align: center;">$u_c = \sqrt{u_1^2 + u_2^2 + u_3^2 + \dots + u_n^2}$</p> <p style="text-align: center;">$V_{eff} = \frac{U_c^2(y)}{\sum \frac{U_i^4}{V_i}}$</p>																																																			
<table style="width: 100%;"> <tr> <td style="text-align: center;">Valor Real (média + erro)</td> <td style="text-align: center;">Variação (U)</td> <td style="text-align: center;">$U = k \cdot U_c$</td> </tr> <tr> <td style="text-align: center;">600,0000</td> <td style="text-align: center;">10,615695</td> <td></td> </tr> </table>				Valor Real (média + erro)	Variação (U)	$U = k \cdot U_c$	600,0000	10,615695																																											
Valor Real (média + erro)	Variação (U)	$U = k \cdot U_c$																																																	
600,0000	10,615695																																																		
<table border="1" style="width: 100%; border-collapse: collapse;"> <tr> <td style="width: 30%;">Valor Real:</td> <td style="width: 40%; text-align: center;">603,7000</td> <td style="width: 30%; text-align: center;">± 10,6157</td> </tr> <tr> <td>Erro do padrão:</td> <td style="text-align: center;">-3,7000</td> <td></td> </tr> <tr> <td>Maior Valor:</td> <td style="text-align: center;">614,3157</td> <td>Menor Valor: 593,0843</td> </tr> </table>				Valor Real:	603,7000	± 10,6157	Erro do padrão:	-3,7000		Maior Valor:	614,3157	Menor Valor: 593,0843																																							
Valor Real:	603,7000	± 10,6157																																																	
Erro do padrão:	-3,7000																																																		
Maior Valor:	614,3157	Menor Valor: 593,0843																																																	