

Uma Proposta de Análise de Biodegradabilidade no Âmbito da Internet das Coisas^{*}

Régis Cardoso^{*} Cristiano André da Costa^{**}
Rodrigo Marques de Figueiredo^{***}

^{} Instituto Senai de Inovação em Engenharia de Polímeros, RS,
(e-mail: regis.cardoso@senairs.org.br).*

*^{**} Laboratório de Inovação de Software (SOFTWARELAB), Programa de Pós Graduação em Computação Aplicada, Universidade do Vale do Rio dos Sinos (UNISINOS), RS (e-mail: cac@unisinoss.br)*

*^{***} Departamento de Engenharia Elétrica - Escola Politécnica, Universidade do Vale do Rio dos Sinos (UNISINOS), RS, (e-mail: marquesf@unisinoss.br).*

Abstract: It is estimated that by 2050 more than 500 million tons 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 doing this work arise. A solution to reduce the accumulation of these polymers is the use of biodegradable materials, which degrade with the environment. A material is considered biodegradable when it degrades naturally through the interaction of microorganisms. The guarantee of biodegradability must be acquired through standardized tests. These tests have a long duration, making the tests massively dependent on the operators, bringing all the complexity of possible errors through the operator's interaction. The objective of this work is to define an automated equipment model to determine the percentage of biodegradability of materials, using Internet of Things and Machine Learning techniques. The studies and automation developed, allowed the collection of data for the implementation of Machine Learning algorithms. Automation has enabled cost reductions for testing, improved accuracy and precision of results. Two machine learning algorithms were tested: Linear Regression and Artificial Neural Networks. At the end, three pieces of equipment were developed to support industry and institutions in the development of new biodegradable materials.

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. Um material é considerado biodegradável quando se degrada naturalmente através da interação de microorganismos. A garantia da biodegradabilidade deve ser adquirida através de testes normalizados. Esses testes possuem uma longa duração, tornando os ensaios massivamente dependentes dos operadores, trazendo toda a complexidade de possíveis erros pela interação do operador. 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 estudos e automatização desenvolvidos, permitiram a coleta de dados para implementação de algoritmos de Aprendizado de Máquina. A automatização possibilitou redução de custos para realização dos ensaios, melhora na exatidão e precisão dos resultados. Foram testados dois algoritmos de aprendizado de máquina: Regressão Linear e Redes Neurais Artificiais. Ao final foram desenvolvidos três equipamentos destinados ao apoio da indústria e instituições no desenvolvimento de novos materiais biodegradáveis.

Keywords: IoT; Biodegradability; Automation; Machine Learning.

Palavras-chaves: IoT; Biodegradabilidade; Automação; Aprendizado de Máquina.

1. INTRODUÇÃO

A área dos materiais poliméricos cresceu muito. Nos últimos 50 anos, os plásticos estão substituindo materiais como papel, madeira e metal. Luyt and Malik (2019). O grande problema dos materiais poliméricos é o seu acúmulo, devido à dificuldade de biodegradação no meio ambiente. Yin and 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 em materiais poliméricos do que em peixes. Hong and Chen (2019). Assim, surgem novas preocupações com relação ao descarte e o que fazer após a utilização desses materiais. Essa 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 microorganismos como bactérias e fungos. D883-20 (2019). Quando um material específico entra no processo de decomposição, ocorre a interação de microorganismos, 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 et al. (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. 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 vem sendo aplicados continuamente para otimização e aprimoramento de processos. Com isso, diariamente surgem novos sensores para diferentes aplicações tornando as máquinas e equipamentos cada vez mais independentes e inteligentes, reduzindo o tempo de intervenção humana, o custo de implementação, aumentando da produtividade, confiabilidade e facilitando

o controle de uma grande quantidade de dados que servirão na tomada de decisões futuras. Xu and Duan (2019).

Algumas vantagens podem ser percebidas quando da utilização de sistemas automatizados com técnicas de IoT:

- **Autonomia:** o sistema é capaz de realizar tarefas sem a intervenção de pessoas;
- **Polivalência:** desenvolvimento de todas as funções de forma automática;
- **Precisão:** as atividades realizadas pelo sistema são conduzidas de forma precisa, gerando valores muito próximos aos reais;
- **Exatidão:** as medidas feitas pelo sistema possuem pouca variabilidade, uma vez que são definidos padrões de controle e medição;
- **Coleta e armazenamento de informações:** um sistema automatizado necessita de sensores, esses sensores fazem a coleta de informações referentes ao processo, servindo como base para tomada de decisões;
- **Centralização de informações:** um sistema automatizado possibilita a utilização de softwares para centralização e disponibilização de informações em um único local, seja em um computador, smartphone ou outro dispositivo móvel com acesso a internet;
- **Integrações:** um sistema automatizado permite a integração com diferentes softwares, bem como implementação de técnicas de aprendizado de máquina, os quais no caso desse trabalho permitem realizar previsões de eventos futuros.

Neste contexto, esse artigo descreve como aplicar conceitos de IoT e aprendizado de máquina, para instrumentação e automação de equipamentos, no caso desse trabalho em específico, equipamentos para determinação do percentual da biodegradabilidade de materiais poliméricos em escala laboratorial. O artigo está dividido em cinco seções: Introdução: mostra um histórico sobre as técnicas que foram utilizadas. Referencial Teórico: descreve conceitos necessários para o entendimento do desenvolvimento do trabalho. Modelo Proposto: é definido o modelo que deseje-se estudar. Validação do modelo: aonde são detalhados as implementações do modelo proposto e os resultados alcançados. Conclusão: mostrando as principais contribuições e ganhos com o desenvolvimento do trabalho.

2. REFERENCIAL TEÓRICO

Para desenvolvimento do presente trabalho é necessário a definição de alguns conceitos. É com base nesses conceitos que serão tomadas algumas decisões para definição do modelo e implementação do equipamento para teste do percentual de biodegradabilidade.

2.1 Evolução da Automação

Podemos entender como Automação, toda e qualquer atividade destinada a reduzir o esforço físico do ser humano. FILIPPO (2014). A utilização demasiada de recursos computacionais e aumento da produtividade, forçou o desenvolvimento da quarta revolução industrial, em 2011. Essa

* Este trabalho é financiado pela CAPES e pelo Instituto Senai de Inovação em Engenharia de Polímeros.

revolução foi denominada de Indústria 4.0. 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 pessoas. Muhuri et al. (2019). Para Aileni et al. (2020) o conceito de Indústria 4.0 é representado por fabricas 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). 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 et al. (2019). Nesse contexto, 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.

2.2 Aprendizado de Máquina

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 and 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 et al. (2016). Uma das áreas da AI é a de Aprendizado de Máquina do inglês - Machine Learning ou somente AM.

Aprendizado de Máquina, trata-se de uma área da Inteligência Artificial aonde deseja-se construir sistemas computacionais que melhorem automaticamente conforme a experiência que é adquirida. Jordan and 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. Os dados coletados serão organizados permitindo uma melhora progressiva do sistema ou equipamento em questão. Xue and Zhu (2009).

2.3 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 sua fabricação de forma ágil, automatizada e limpa,

até o descarte e seu tempo de vida útil. Isso resultou na busca por outros tipos de materiais mais nocivos 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 Manufacturers (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).

Segundo ASTM D883-20 (2019) polímeros biodegradáveis são aqueles que degradam de forma natural, através da presença de microrganismos como bactérias e fungos. Para que um material seja declado como biodegradável é necessário a realização de alguns ensaios seguindo normas nacionais ou internacionais. Essas normas atestam o percentual da biodegradabilidade de materiais, utilizando escalas laboratoriais, simulando ambientes marinhos e solos, com processos aeróbicos e anaeróbicos.

O percentual de biodegradabilidade é dado com base na emissão de Dióxido de Carbono (CO_2) que é liberado pelo ataque dos microrganismos na amostra em teste. Inicialmente é definido o valor teórico conforme equação 1 em seguida é determinado o percentual de biodegradabilidade, através da equação 2:

$$ThCO_2 = M \times C \times \frac{44}{12} \quad (1)$$

No qual:

M: massa do material testado (g);

C: determinação do teor organico total da amostra de teste TOC (%);

44/12: massa molar do CO_2 .

$$D = \frac{TCO_2 \times BCO_2}{ThCO_2} \times 100 \quad (2)$$

No qual:

TCO_2 : valor de CO_2 medido no reator de teste com amostra e solo (g);

BCO_2 : valor de CO_2 medido somente no solo (branco) (g);

$ThCO_2$: valor teórico estimado de CO_2 .

Além dos controles de emissão de CO_2 outras variáveis devem ser controladas, 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. O percentual da biodegradabilidade é tomado com base na emissão de CO_2 pelos microrganismos que estão interagindo com a

amostra de teste. A evolução do CO_2 deve ser acompanhado diariamente durante um período de teste que pode variar entre 90 e 180 dias. Com isso, é possível perceber que os dados formam um série temporal. Como os testes são longos, esse trabalho é desenvolvido tomando duas frentes de atuação, a primeira aonde é feito a automatização dos testes aplicando técnicas de IoT e a segunda aonde são aplicados algoritmos de aprendizado de máquina para predição de séries temporais, possibilitando a redução dos tempos reais de teste. Neste contexto, podemos destacar as revisões sistemáticas de Martínez-Álvarez et al. (2015), Deb et al. (2017) e Voyant et al. (2017), que fazem discussões sobre técnicas de aprendizado de máquina aplicado na previsão de séries temporais. Os autores demonstram que o estado da arte para algoritmos de predição em séries temporais está na aplicação de algoritmos de Regressão e RNA.

3. MODELO PROPOSTO

Um modelo para automatização de testes de biodegradabilidade é definido conforme Figura 1.

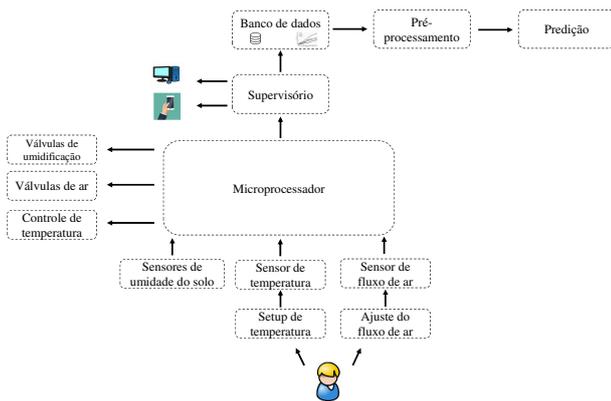


Figura 1. Modelo proposto para implementação de um equipamento automatizado para realização de testes do percentual de biodegradabilidade de materiais.

O modelo proposto é constituído de dois módulos, o primeiro no que diz respeito a um sistema de IoT e o segundo aonde acontece a implementação dos algoritmos de aprendizado de máquina.

3.1 Módulo IoT

O módulo de IoT é de fundamental importância no desenvolvimento desse trabalho, é nele aonde as informações são recebidas, processadas e armazenadas. O módulo IoT é detalhado a seguir:

- **Sensores:** permitem a implementação de um sistema automatizado, são responsáveis por converter grandezas físicas em sinais elétricos, possibilitando o controle sobre 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 $58 ^\circ C \pm 2 ^\circ C$), 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).

- **Atuadores:** possibilitam o controle das variáveis já mencionadas, no caso dessa aplicação, esses atuadores tratam-se de válvulas, as quais são utilizadas, para controle automático da umidade e direcionamento do fluxo de ar de cada reatores de teste para medição do CO_2 gerado.
- **Microncontrolador:** a utilização de sistemas microncontrolados 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.
- **Sistema supervisorio:** 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.
- **Banco de dados:** 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.

3.2 Módulo de aprendizado de máquina

A segunda parte do modelo é direcionada para implementação dos algoritmos de aprendizado de máquina, é aqui aonde são feitas as predições do percentual de biodegradabilidade, permitindo a redução dos tempos reais de teste os quais podem variar entre 90 e 180 dias.

- **Pré-processamento:** aqui são realizados tratamentos estatísticos para verificação do comportamento e seleção das curvas de ensaios adequadas para realização de predições, além da normalização dos dados, preenchimento de valores faltantes e exclusão de dados nulos ou incoerentes (fora do padrão);
- **Predição:** trata-se da parte aonde os resultados são processados e expandidos conforme tempo pré-determinado, ou seja, aqui será realizado a implementação de um algoritmos de aprendizado de máquina utilizando Regressão Linear 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.

4. MATERIAIS E METÓDOS

Para realizar a validação do modelo proposto foi desenvolvido um protótipo. Esse protótipo foi montado tomando como base sensores de baixo custo, no qual o interfaceamento da implementação é mostrada na Figura 2.

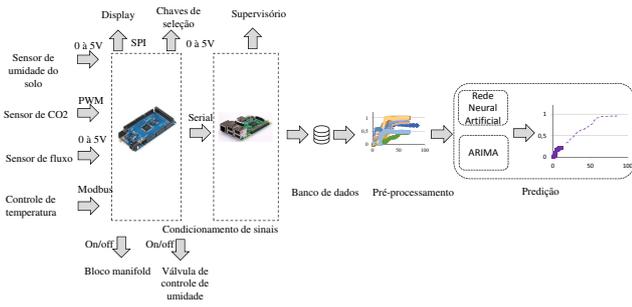


Figura 2. Interfaceamento proposto para validação do modelo.

Serão utilizados dois dispositivos de processamento. O primeiro dispositivo de trata-se de um microprocessador ATmega2560 embarcado em Arduino, 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 Arduino para uma placa Raspberry pi 3 modelo B embarcado com Linux, a qual irá armazenar todas as informações e disponibilizá-las para os usuários através de um sistema supervisão. Os dados coletados e armazenados pela Raspberry serão utilizados para implementação de um sistema de predição de resultados. Optou-se pela utilização da placa Arduino, 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. É importante salientar essas placas serão utilizadas somente para validação do modelo proposto, sendo necessário a utilização de outro dispositivo industrial para implementação dos equipamentos finais.

O controle de temperatura é feito por uma câmara de aquecimento aonde é utilizado um sensor do tipo pt100 interligado a um controlador da Novus modelo N120 que faz o controle de um relé de estado sólido para acionamento das resistências, através de um controle PID – Proporcional Integral Derivativo, permitindo um controle de temperatura preciso.

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. Adla et al. (2020) comparam sensores resistivos e capacitivos de baixo custo e chegam a conclusão que os sensores capacitivos possuem melhor desempenho quando comparado com os resistivos, justificando assim a utilização de sensores capacitivos.

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. Foram testados alguns sensores para serem utilizados na aplicação. Os testes foram feitos tomando como base uma mistura de gás padrão, a qual se tinha conhecimento dos valores de composição. Foi possível perceber que o sensor

Mhz-14a mediu valores satisfatórios. Porém, foi necessário respeitar o tempo de estabilização do sensor.

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 em gramas (g) gerado pelos microorganismos presentes no composto de teste, é realizado um cálculo tomando como base as equações 3 e 4 para conversão dos valores de CO_2 de ppm para gramas.

$$CO_2(g) = \frac{F \times CO_2(ppm) \times t \times M(CO_2)}{V \times 10^6} \quad (3)$$

$$V = R \times \frac{T}{P} \quad (4)$$

No qual:

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.

O fluxo de ar será controlado por um sensor modelo GFC da marca Aalborg, esse sensor possui uma saída de tensão (0 à 5V) facilitando a medição através da placa ATmega2560. 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.

Os frascos aonde serão depositados os materiais de teste são denominados como reatores. Esse reatores possuem uma entrada e uma saída de ar. Para realização do controle de umidade dos testes, foi feito mais um entrada para conexão de um sistema de irrigação controlado automaticamente por válvulas solenóides.

Além dos itens já mencionados, foram também necessários um bloco manifold para interconexão das saída dos reatores de teste a um único sensor de CO_2 .

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 tensão de 0 à 5 VDC, 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 é feita por comunicação serial.

Será utilizado o software Weka, para implementação dos algoritmos de aprendizado de máquina destinado a pre-

visão de resultados. 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). Justifica-se a utilização do Weka nesse primeiro momento para validação do modelo de aprendizado de máquina definido.

Inicialmente foi necessário o levantamento dos ensaios reais já realizados, esse levantamento resultou em 33 polímeros já testados pelo Instituto de Inovação da Engenharia de Polímeros SENAI - ISI Polímeros, após a aplicação do pré-processamento de dados, os dados foram analisados e excluímos 2 polímeros com comportamentos incoerentes verificados através de testes de correlação estatística.

Para os algoritmos de Redes Neurais Artificiais - RNA, foram aplicados o mecanismo de janela ou lag. Essas janelas são como uma memória da rede, tornando a rede capaz de aprender comportamentos temporais não estacionários, através da aplicação de um atraso de tempo. Deb et al. (2017). Foram testadas várias cargas de atraso, o que teve melhor resposta foi de 7 dias. A taxa de aprendizado para atualização dos pesos foi de 0,01. O momentum aplicado foi de 0,1. O tempo de treinamento foi de 2000 épocas. Foi utilizada como função de ativação dos neurônios da Rede Neural a função sigmóide. Tanto para os algoritmos de Regressão quanto para os de RNA os dados de entrada foram inseridos com 35 dias reais de ensaio e previsto os dados para os próximos 100 dias subsequentes.

5. RESULTADOS

Para realizar a validação do modelo proposto foi realizado a montagem de um protótipo com três configurações diferentes conforme figura 3. O teste foi conduzido por um período de 45 dias. Conforme as normas de referência para esses testes, espera-se que após esses dias, pó de celulose, chegue a pelo menos 70 % de biodegradabilidade.

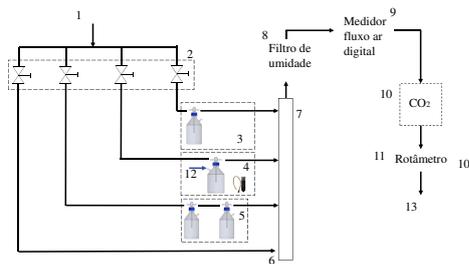


Figura 3. Configurações de teste.

Um sistema de injeção de ar (1), faz com que o ar circule entre os reatores de teste até a saída do sistema (13). Válvulas de controle de fluxo manual (2) devem ser ajustadas no início do processo, o fluxo de ar de cada reator é verificado no rotâmetro (11). Os três primeiros reatores não possuem nenhum tipo de controle de umidade (3), os próximos três (4) têm uma entrada de água (12) automática controlada por uma eletroválvula e sensores de umidade do solo, os últimos reatores (5) utilizam a

metodologia de teste adotada por alguns artigos e pelas normas de referência, aonde 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. Os reatores são interconectados através de um bloco manifold (7) o qual modula a leitura de CO_2 , permitindo a leitura de um reator por vez por um único sensor (10). Além disso foi instalado um sistema de retirada de umidade para evitar uma possível danificação do sensor (8) e medidor de fluxo de ar digital (9) para possibilitar a conversão de ppm para gramas de CO_2 . A entrada (6) faz a limpeza e descontaminação do sistema entre as leituras de cada reator.

Observando a Tabela 1 e o gráfico 4 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 (pó de celulose) atingisse o percentual mínimo exigido. O controle de umidade por sensores garantiu que a celulose chegasse a 72 % de biodegradabilidade.

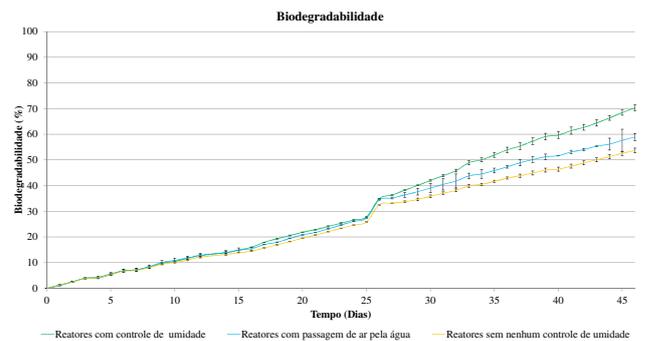


Figura 4. Resultados alcançados para o modelo proposto.

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 ASTM 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 1. Dessa forma pode-se perceber que o controle sensorizado de umidade é fundamental para garantir a validade dos testes, nas configurações testeadas.

Tabela 1. Medição de umidade para validação do modelo ao final dos 45 dias de teste, o desvio padrão foi calculado para uma amostra de 3 medições ($n = 3$).

Método	Umidade (%UR)	Desvio padrão (%UR)
Umidificação do ar	11,8	0,19
Umidade por sensor	44,5	2,12
Nenhum controle	8,1	0,47

Os resultados apresentados na Tabela 1 e Figura 4 validam a metodologia de controle de umidade do solo por sensores

e dispositivos de irrigação, definindo essa como o padrão a ser utilizado na montagem final do equipamento de teste do percentual da biodegradabilidade de materiais.

Após a validação do modelo de IoT foi realizada a implementação dos algoritmos de Regressão Linear e RNA, os resultados podem ser observados nas Figuras 5, 6 e 7.

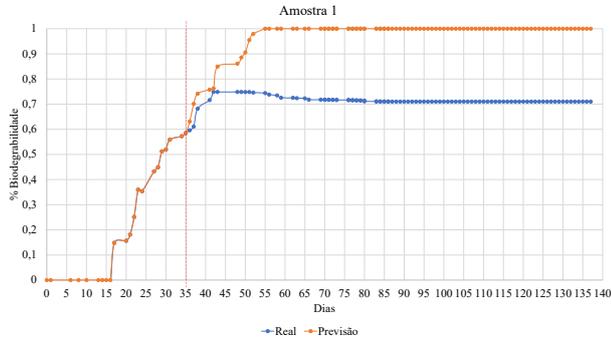


Figura 5. Resultados alcançados para RNA para amostra 1 do banco de dados.

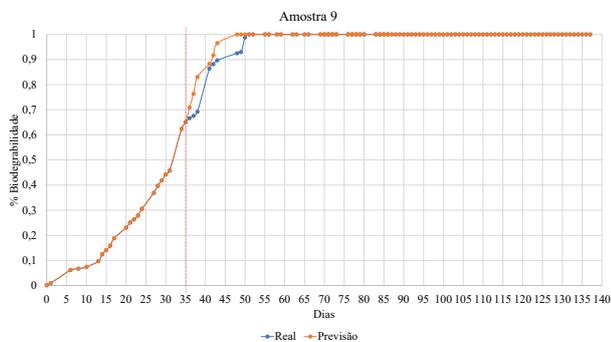


Figura 6. Resultados alcançados para RNA para amostra 9 do banco de dados.

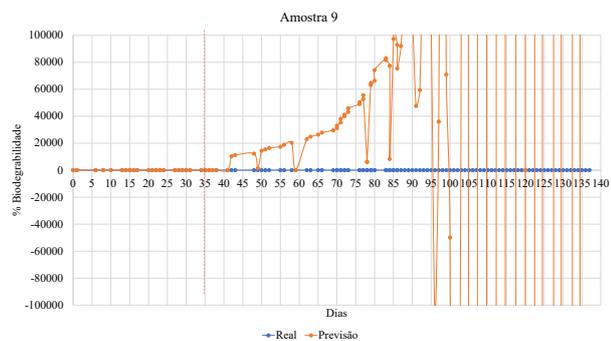


Figura 7. Resultados alcançados para regressão linear para amostra 9 do banco de dados.

Os algoritmos de Regressão Linear, tiveram um funcionamento ineficiente para as amostras de ensaios de biodegradabilidade. Logo é apresentado apenas uma previsão e nesse caso não foi executado nenhum cálculo de acurácia para esse algoritmo. Já os resultados apresentados pelo algoritmos de RNA desmonstraram previsões coerentes, tornando possível a previsões para todas as 31 amostras de materiais poliméricos já testados até o momento.

A Tabela 2 mostra os resultados de acurácia para a melhor e pior predição, ou seja, a amostra 1 representa os piores resultados alcançados e a amostra 9 os melhores.

Tabela 2. Análises de acurácia para RNA

Amotras	MAD	MSE	RMSE	MAPE
Amostra 1	0,221	0,061	0,247	38,004
Amostra 9	0,005	0,000	0,020	0,598

6. CONCLUSÃO

Esse trabalho apresentou a validação de um modelo automatizado para determinação da biodegradabilidade de materiais. Foram testados diferentes sensores de baixo custo e aplicando técnicas de IoT e aprendizado de máquina. Foi realizada a montagem de três configurações diferentes de controle da umidade do solo. 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 . Além disso foram os únicos reatores que mantiveram o valor de umidade próximos ao valor necessário para o teste, medido ao final do experimento por procedimentos padrões de determinação de umidade em solo.

A validação do protótipo demonstra os benefícios que foram alcançados na aplicação de conceitos de IoT e automação, além da melhoria no controle das variáveis envolvidas no processo, foi possível a aplicação de algoritmos de aprendizado de máquina reduzindo os tempos reais de teste que antes variavam de 90 a 180 dias. Após a validação do modelo a utilização de algoritmos de aprendizado de máquina possibilitou a projeção dos resultados do percentual da biodegradabilidade, com apenas 35 dias de ensaio, sendo possível prever 100 dias a frente.

O sucesso dos testes validados em um protótipo, resultaram na montagem de outros três equipamentos, que podem ser observados na Figura 8 os quais já estão em operação e disponíveis para realização de testes à indústrias de desenvolvimento de novos materiais poliméricos, no Instituto SENAI de Inovação em Engenharia de Polímeros - ISI Polímeros ¹.



Figura 8. Equipamentos desenvolvidos e em operação no Instituto Senai de INovação em Engenharia de Polimeros em São Leopoldo - RS.

Como trabalhos futuros deseja-se explorar as técnicas de aprendizado de máquina, utilizando softwares dedicados como Scikit Learning ou Keras, permitindo maiores ajustes e aplicação de outras técnicas de aprendizado de máquina como por exemplo Redes Neurais Artificiais Recorrentes e ARIMA.

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

AGRADECIMENTOS

Este trabalho foi parcialmente financiado pela CAPES.

Os componentes para os testes e montagem dos equipamentos foram disponibilizados junto ao Instituto de Inovação da Engenharia de Polímeros SENAI.

REFERÊNCIAS

- Abiplast - Associação Brasileira da Indústria do Plástico (2019). Perfil 2018. Disponível em: http://www.abiplast.org.br/wp-content/uploads/2019/10/perfil2018-web_VC.pdf. Access in: march 2020.
- Adla, S., Rai, N.K., Sri Karumanchi, H., Tripathi, S., Disse, M., and Pande, S. (2020). Laboratory calibration and performance evaluation of low-cost capacitive and very low-cost resistive soil moisture sensors. *Sensors*, 20(2), 363.
- Aileni, R.M., George, S., Pasca, S., and Alberto, V.S.C. (2020). Data fusion-based ai algorithms in the context of iiots. In *Internet of Things for Industry 4.0*, 17–38. Springer.
- Alpaydin, E. (2020). *Introduction to machine learning*. MIT press.
- Corral-Plaza, D., Medina-Bulo, I., Ortiz, G., Boubeta-Puig, J., Group, U.S.E.R., et al. (2020). A stream processing architecture for heterogeneous data sources in the internet of things. *Computer Standards & Interfaces*, 70, 103426.
- D2216-19, A. (2019). Standard method of laboratory determination of moisture content of soil.
- D883-20, A. (2019). Standard terminology relating to plastics.
- Deb, C., Zhang, F., Yang, J., Lee, S.E., and Shah, K.W. (2017). A review on time series forecasting techniques for building energy consumption. *Renewable and Sustainable Energy Reviews*, 74, 902–924.
- Domingos, P. (2012). A few useful things to know about machine learning. *Communications of the ACM*, 55(10), 78–87.
- FILIPPO, G. (2014). Automação de processos e de sistemas. 1. São Paulo: Érica, 144.
- Frank, A.G., Dalenogare, L.S., and Ayala, N.F. (2019). Industry 4.0 technologies: Implementation patterns in manufacturing companies. *International Journal of Production Economics*, 210, 15–26.
- Hong, M. and Chen, E.Y.X. (2019). Future directions for sustainable polymers. *Trends in Chemistry*, 1(2), 148–151.
- Jordan, M.I. and Mitchell, T.M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255–260.
- Kagermann, H., Anderl, R., Gausemeier, J., Schuh, G., and Wahlster, W. (2016). *Industrie 4.0 in a Global Context: strategies for cooperating with international partners*. Herbert Utz Verlag.
- Lima, I., Pinheiro, C.A., and Santos, F.A.O. (2016). *Inteligência artificial*, volume 1. Elsevier Brasil.
- Luyt, A.S. and Malik, S.S. (2019). Can biodegradable plastics solve plastic solid waste accumulation? In *Plastics to Energy*, 403–423. Elsevier.
- Madakam, S., Lake, V., Lake, V., Lake, V., et al. (2015). Internet of things (iot): A literature review. *Journal of Computer and Communications*, 3(05), 164.
- Martínez-Álvarez, F., Troncoso, A., Asencio-Cortés, G., and Riquelme, J.C. (2015). A survey on data mining techniques applied to electricity-related time series forecasting. *Energies*, 8(11), 13162–13193.
- Mellit, A. and Kalogirou, S.A. (2008). Artificial intelligence techniques for photovoltaic applications: A review. *Progress in energy and combustion science*, 34(5), 574–632.
- Muhuri, P.K., Shukla, A.K., and Abraham, A. (2019). Industry 4.0: A bibliometric analysis and detailed overview. *Engineering applications of artificial intelligence*, 78, 218–235.
- Nilsson, N.J. (2014). *Principles of artificial intelligence*. Morgan Kaufmann.
- Pacchini, A.P.T., Lucato, W.C., Facchini, F., and Mummolo, G. (2019). The degree of readiness for the implementation of industry 4.0. *Computers in Industry*, 113, 103125.
- Plastics Europe - Association of Plastics Manufactures (2019). Plastics – the facts 2019 - an analysis of european plastics production, demand and waste data. Disponível em: https://www.plasticseurope.org/application/files/1115/7236/4388/FINAL_web_version_Plastics_the_facts2019_14102019.pdf. Access in: march 2020.
- Ruggero, F., Gori, R., and Lubello, C. (2019). Methodologies to assess biodegradation of bioplastics during aerobic composting and anaerobic digestion: A review. *Waste Management & Research*, 37(10), 959–975.
- Silveira, A., Moreno, J.R., Correia, M.J., and Ferro, V. (2019). A method for the rapid evaluation of leather biodegradability during the production phase. *Waste management*, 87, 661–671.
- Turing, A.M. (2009). Computing machinery and intelligence. In *Parsing the Turing Test*, 23–65. Springer.
- Voyant, C., Notton, G., Kalogirou, S., Nivet, M.L., Paoli, C., Motte, F., and Fouilloy, A. (2017). Machine learning methods for solar radiation forecasting: A review. *Renewable Energy*, 105, 569–582.
- Weka - The workbench for machine learning (2020). Weka. Disponível em: <https://waikato.github.io/weka-wiki/documentation/>. Access in: may 2020.
- Xu, L.D. and Duan, L. (2019). Big data for cyber physical systems in industry 4.0: A survey. *Enterprise Information Systems*, 13(2), 148–169.
- Xue, M. and Zhu, C. (2009). A study and application on machine learning of artificial intelligence. In *2009 International Joint Conference on Artificial Intelligence*, 272–274. IEEE.
- Yin, G.Z. and Yang, X.M. (2020). Biodegradable polymers: a cure for the planet, but a long way to go. *Journal of Polymer Research*, 27(2), 38.