

UNIVERSIDADE DE SÃO PAULO
ESCOLA POLITÉCNICA
DEPARTAMENTO DE ENGENHARIA METALÚRGICA E DE MATERIAIS

ISABELLA CASEMIRO PERINI

**RECONHECIMENTO DE IMAGENS DE MICROESTRUTURAS DE AÇOS COM
INTELIGÊNCIA ARTIFICIAL WATSON**

São Paulo
2019

ISABELLA CASEMIRO PERINI

Reconhecimento de imagens de microestruturas de aços com inteligência artificial Watson

Versão Original

Monografia apresentada ao Departamento de Engenharia Metalúrgica e de Materiais da Escola Politécnica da Universidade de São Paulo para obtenção do título de Engenheira de Materiais.

Área de concentração:

Orientador: Prof. Dr. André Paulo Tschiptschin

São Paulo
2019

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

Ficha Catalográfica

Perini, Isabella

Reconhecimento de imagens de microestruturas de aços com inteligência artificial Watson / I. Perini -- São Paulo, 2019.

123 p.

Trabalho de Formatura - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia Metalúrgica e de Materiais.

1.INTELIGÊNCIA ARTIFICIAL 2.METALOGRAFIA MICROSCÓPICA
3.AÇO 4.RECONHECIMENTO DE IMAGEM I.Universidade de São Paulo.
Escola Politécnica. Departamento de Engenharia Metalúrgica e de Materiais
II.t.

AGRADECIMENTOS

Inicialmente, gostaria de agradecer ao prof. André Paulo Tschiptschin pela orientação neste trabalho e pelas importantes aulas de metalografia lecionadas durante o semestre.

Agradeço ao pessoal da IBM, onde a ideia deste trabalho surgiu. Obrigada a turma do ThinkLab, Hvon (Henrique von Atzingen) e Andrea Britto Mattos Lima, que me orientaram nos primeiros passos. Obrigada também aos desenvolvedores responsáveis pelo aulão do Visual Recognition, que facilitou muito o entendimento deste produto. Agradeço também ao meu time da IBM, que entendeu o meu momento de final de curso e sempre apoiou a ideia e meus estudos.

Obrigada aos amigos Zeca (Jose Raphael Teodoro Coelho Novaes), Leo (Leonardo Furniellis) e Piazza (Gabriel Piazzalunga) pela grande ajuda com o desenvolvimento da página web.

Obrigada aos amigos da Poli, especialmente a minha turma de metalografia deste ano, que me passou diversas imagens e ainda foram os usuários finais, respondendo a mais um dos meus memoráveis formulários. Um agradecimento especial aos monitores da disciplina de metalografia, Julián David Escobar Atehortúa, Luiz Felipe Bauru e Rafael Rocha Maia, que muito me ajudaram com o modelo, seja pelas imagens concedidas ou pela torcida positiva. Obrigada também aos meus amigos mais próximos por todo o apoio e motivação.

Agradeço ao Leandro Nunes por ajudar a manter minha saúde física e tentar equilibrar a mental através da endorfina produzida nos exercícios semanais.

Ainda, gostaria de agradecer a família Ramalli, Dalva, Silvio e Sophia pelo apoio e momentos de descontração e Fernando, meu companheiro, por tudo. Por fim, agradeço imensamente a minha família, que aguentou meu *stress* durante esse período, principalmente aos meus pais, por sempre acreditarem em mim e me ajudarem a chegar até aqui.

RESUMO

PERINI, Isabella Casemiro. **Reconhecimento de imagens de microestruturas de aços com inteligência artificial Watson**. 2019. 123 p. Monografia (Graduação em Engenharia de Materiais) – Departamento de Engenharia Metalúrgica e de Materiais (PMT), Escola Politécnica da Universidade de São Paulo, São Paulo, 2019.

O presente estudo é uma investigação preliminar da utilização da inteligência artificial da IBM, Watson, no reconhecimento de imagens de microestruturas. Para isso, selecionou-se o caso de uso de microestruturas de aços, atacados com Nital, cuja aplicação é voltada para o âmbito acadêmico, como ferramenta de apoio a alunos universitários. O classificador foi desenvolvido através dos produtos Watson™ Visual Recognition, que contém os algoritmos de *deep learning*, e o Watson™ Studio, interface para auxílio na criação do modelo. As imagens foram obtidas de diversas fontes, como livros acadêmicos, bancos de dados e artigos disponíveis na internet, além de imagens analisadas em aula no laboratório de metalografia da Escola Politécnica da USP. A primeira versão do modelo foi treinada para 4 classes de microconstituintes: carbonetos, ferrita, ferrita e perlita, e martensita (placas). Foram utilizadas 501 imagens no total, sendo estipulado um valor mínimo de 80 imagens de treinamento por classe, seguindo a proporção de 80% das imagens para treinamento e 20% para testes. A primeira versão alcançou acurácia média de 91,9%. A primeira versão do modelo foi levada a um ambiente de produção, a partir do qual os usuários finais, ou seja, alunos e pesquisadores da Universidade de São Paulo, puderam interagir e fornecer feedbacks. Os feedbacks recolhidos desta etapa foram utilizados para refinar o modelo, acrescentando novas imagens às classes já montadas e uma nova classe, a martensita e austenita, além de complementar a classe já existente de martensita com imagens da mesma em morfologia de ripas. Esta segunda versão do modelo utilizou 725 imagens únicas no banco de treinamento e alcançou acurácia de 96,4%. O estudo atingiu seus objetivos e comprovou a adequação dos algoritmos do Watson™ Visual Recognition para classificar microestruturas de aços, mesmo com um banco de imagens muito amplas, obtidas de inúmeras fontes e com qualidade diversa. Os resultados levam a crer que estes produtos da IBM podem ser utilizados com sucesso em tarefas de classificação qualitativa de micrografias, e até mesmo em tarefas quantitativas, caso a padronização das imagens no banco de treinamento seja alta.

Palavras-chave: Aços. Microestrutura. Reconhecimento de imagens. Inteligência artificial.

ABSTRACT

PERINI, Isabella Casemiro. **Image recognition of steels microstructure using artificial intelligence Watson**. 2019. 123 p. Undergraduate thesis (Materials Engineering Degree) – Departamento de Engenharia Metalúrgica e de Materiais (PMT), Escola Politécnica da Universidade de São Paulo, São Paulo, 2019.

This study is a preliminary investigation regarding the use of IBM's artificial intelligence (AI), Watson, applied to the field of metallographic image recognition, most specifically, steels microstructure, Nital etched, as a use case for an academic support tool for university students. A classifier was developed with IBM cloud's products, such as Watson visual recognition (containing the AI deep learning algorithms) and Watson studio (classifier creation support interface). Image database was assembled based on many resources, like academic books, online image databases and scientific articles, besides images collected from laboratory classes in the Escola Politécnica (Universidade de São Paulo - USP) metallographic lab. The first version of the model was trained to recognize 4 microconstituents classes: carbides, ferrite, ferrite and pearlite, and martensite (plate morphology). There was a total of 501 images used for training and testing the model, with at least 80 training images for each class, following established proportions of 80% training - 20% testing. This first version of the model achieved 91,9% of average accuracy. It was deployed as a web page, from which final users (students and researchers from USP) could interact and provide feedback. The feedback collected were used to refine the model into a new version, adding new images to the previous classes and creating a new class, martensite and austenite, besides complementing the existing martensite class with images of its lath morphology. The second version of the model used 725 images for training and achieved an average accuracy of 96,4%. This study accomplished its goals and proved that Watson visual recognition can be used to classify steels microstructure, even when the image database was diverse, obtained from many resources with varying quality. The results suggest that the IBM's products used can be successfully applied to qualitative micrograph classification tasks and even to quantitative tasks, if there is high standardization of images in the database.

Keywords: Steels. Microstructure. Image recognition. Artificial intelligence.

SUMÁRIO

1	INTRODUÇÃO	1
1.1	OBJETIVOS	3
2	REVISÃO BIBLIOGRÁFICA	4
2.1	MATERIAIS DE INTERESSE	4
2.1.1	Ferro	4
2.1.2	Aço	5
2.2	PRINCIPAIS FASES DOS AÇOS	7
2.2.1	Ferrita	11
2.2.1.1	Ferro- α	11
2.2.1.2	Ferro- δ	12
2.2.2	Austenita	12
2.2.3	Cementita	12
2.2.4	Perlita	13
2.2.5	Martensita e Bainita	15
2.2.6	Grafita	17
2.3	COMPUTAÇÃO COGNITIVA	17
2.3.1	Machine Learning	19
2.3.1.1	Tipos de Algoritmos	21
2.3.1.1.1	<i>Algoritmos Supervisionados</i>	21
2.3.1.1.2	<i>Algoritmos Não Supervisionados</i>	21
2.3.1.1.3	<i>Algoritmos de Reforço</i>	22
2.3.1.2	Deep Learning	22
2.3.2	Inteligência Artificial	23
2.3.2.1	IBM Watson®	27
2.3.2.1.1	<i>Medicina: IBM® Watson Health™</i>	29
2.3.2.1.2	<i>Otimização do processo de pré-vendas: Gerdau</i>	30
2.3.2.1.3	<i>Reconhecimento de Imagens: IBM Watson® Visual Recognition e Volkswagen Virtus</i>	30
2.4	RECONHECIMENTO DE IMAGENS	31
2.4.1	Aplicação no campo de Engenharia de Materiais e Metalúrgica	32
3	METODOLOGIA E PLANO DE TRABALHO	38

3.1	METODOLOGIA SUGERIDA PARA PROJETOS DE INTELIGÊNCIA ARTIFICIAL	38
3.1.1	Fase 1 do Ciclo de AI: Design e Planejamento	39
3.1.2	Fase 2 do Ciclo de AI: Dados	39
3.1.3	Fase 3 do Ciclo de AI: Treinamento	40
3.1.4	Fase 4 do Ciclo de AI: Inferência	40
3.1.5	Fase 5 do Ciclo de AI: Evolução	41
3.2	IBM WATSON® VISUAL RECOGNITION E IBM WATSON® STUDIO.....	42
3.3	MÉTODO ADOTADO / PLANO DE TRABALHO	46
3.3.1	Design e Planejamento	46
3.3.2	Dados	47
3.3.3	Treinamento	51
3.3.3.1	Metodologia para sorteio das imagens.....	52
3.3.3.2	Prova de compatibilidade e utilização do Watson™ Visual Recognition	53
3.3.3.3	Teste e avaliação dos resultados do modelo	55
3.3.3.4	Construção da primeira versão do modelo de classificação de microestruturas de aços.....	56
3.3.4	Inferência	59
3.3.5	Evolução	63
4	RESULTADOS E DISCUSSÕES	68
4.1	PROVA DE COMPATIBILIDADE	68
4.2	PRIMEIRO CICLO DE INTELIGÊNCIA ARTIFICIAL.....	70
4.2.1	Treinamentos da primeira versão do modelo	70
4.3	SEGUNDO CICLO DE INTELIGÊNCIA ARTIFICIAL	83
4.3.1	Resultados obtidos da implementação da primeira versão do modelo	83
4.3.2	Treinamentos da segunda versão do modelo	85
4.4	DISCUSSÕES.....	91
5	CONCLUSÃO/ CONSIDERAÇÕES FINAIS	98
6	SUGESTÕES PARA TRABALHOS FUTUROS	100

LISTA DE ILUSTRAÇÕES

Figura 1 – Diagrama de equilíbrio metaestável de fases binário Fe-C.....	8
Figura 2 – Diagramas de fase Fe-C metaestável (a) e estável (b).....	10
Figura 3 – Microestrutura da ferrita (α)	11
Figura 4 – Filme de cementita nos contornos de grãos perlíticos em um aço hipereutetóide	13
Figura 5 – Perlita em aço eutetóide	14
Figura 6– Bainita.....	15
Figura 7 – Martensita em ripas em aço baixo carbono	16
Figura 8 – Martensita em placas em liga Fe-C com 1,86% em peso de C	17
Figura 9 – Fluxograma de desenvolvimento de modelo de <i>Machine Learning</i>	20
Figura 10 – Categorias de definições de Inteligência Artificial	24
Figura 11 – Disputa de <i>Jeopardy!</i> entre Watson™ (no meio) e os campeões Ken Jennings (à esquerda) e Brad Rutter (à direita).....	28
Figura 12 – Esquema representativo do Ciclo de AI	42
Figura 13 – Arquitetura de integração entre os serviços IBM e os usuários.....	43
Figura 14 – Tela com parâmetros de API e informações gerais da instância de Watson™ Visual Recognition criada.....	44
Figura 15 – Região e grupo de hospedagem das instâncias	45
Figura 16 – Tela de edição do modelo no Watson™ Studio	45
Figura 17 – Comparação entre a morfologia da ferrita: (a) pura (b) em uma microestrutura com presença majoritária de perlita (componente escuro).	48
Figura 18 – Simulação de cortes realizados em uma imagem do banco de dados para remoção da grade de escala	50
Figura 19 – Classes criadas para a prova de fogo. Apenas imagens de treinamento deverão ser adicionadas às classes.	54
Figura 20 – Tela do Watson™ Visual Recognition mostrando que o modelo está pronto para ser treinado	55
Figura 21 – Tela do Watson™ Visual Recognition mostrando as novas classes criadas	58
Figura 22 – Fluxo dos blocos de programação utilizados na interface do Node-RED.	60
Figura 23 – Página inicial da aplicação. Em rosa, está o link que direciona o usuário para a página de geração de URL via Imgur.....	62
Figura 24 – Página de resultados da aplicação. O formulário do Google Forms pode ser acessado clicando em “este formulário”, em rosa.	63

Figura 25 – Novo modelo desenvolvido com mais imagens e mais classes.....	66
Figura 26 – Resultado de algumas das imagens de teste desta etapa. As duas imagens superiores possuem microestrutura de ferrita e perlita, enquanto as duas inferiores são representativas de martensitas	69
Figura 27 – Resultados dos testes com manipulação das imagens 1 e 2	72
Figura 28 – Resultados obtidos na classificação das imagens da rodada de teste 2. Relacionando com a tabela, da esquerda para a direita, as imagens são: (1) 10, 11, 4, 6; (2) 8, 9, 5, 7; (3) 1, 2, 3.	76
Figura 29 – Resultados obtidos com a imagem 1 cortada.....	77
Figura 30 – Testes realizados com a imagem 5 manipulada: (a) ajuste de <i>sharpness</i> e (b) recorte da imagem em (a).	78
Figura 31 – Presença relevante de cementita (preta) em uma matriz de ferrita (branca)	82
Figura 32 – Resultados obtidos na classificação de imagens alteradas da rodada de teste 3. Relacionando com a tabela, da esquerda para a direita, as imagens são alteradas a partir de: (1) 3, 4, 6, 11; (2) 3, 5.	82
Figura 33 – Resultados da interação dos usuários finais com o modelo	84
Figura 34 – Compilado das imagens que apresentaram pior classificação nesta etapa de testes	90
Figura 35 – Microestrutura composta por martensita (clara), perlita (escura e arredondada) e bainita (escura e acicular). Além disso, há presença de ferrita (também clara), conforme indicada na imagem.	92

LISTA DE TABELAS

Tabela 1 – Abundância dos Elementos na Crosta Terrestre	4
Tabela 2: Principais fases e microconstituintes encontrados no equilíbrio Fe-C.....	10
Tabela 3 – Resumo da quantidade de novas imagens adicionadas na segunda versão do modelo	65
Tabela 4 – Resultados da rodada de teste entre Ferrita&Perlita e Martensita (rodada 1)	70
Tabela 5 – Resultados das imagens com pior classificação na rodada de teste 1	71
Tabela 6 – Resultados dos testes com as imagens de pior classificação após adição de novas 4 imagens a classe Martensita	73
Tabela 7 – Resultados da rodada de teste entre Ferrita&Perlita, Martensita e Carbonetos (rodada 2).....	74
Tabela 8– Resultados dos testes com as imagens de pior classificação na rodada de teste 2	75
Tabela 9 – Resultados da rodada de teste entre Ferrita&Perlita, Martensita, Carbonetos e Ferrita (rodada 3)	79
Tabela 10 – Comparação da acurácia geral com cada classe adicionada.....	80
Tabela 11 – Resultados dos testes com as imagens de pior classificação na rodada de teste 3	81
Tabela 12 – Resultados da rodada de teste entre Ferrita&Perlita, Martensita, Carbonetos, Ferrita e Martensita&Austenita.....	85
Tabela 13 – Comparação dos resultados da primeira e segunda versão do modelo ...	86
Tabela 14 – Resultados comparativos entre Martensita e Martensita&Austenita	86
Tabela 15 – Piores resultados obtidos nos testes da classe Martensita&Austenita	88
Tabela 16 – Piores resultados dos testes da segunda versão do modelo, excluindo a classe Martensita&Austenita	89

1 INTRODUÇÃO

A metalografia é o estudo de materiais metálicos através da macro e microscopia, investigando componentes microestruturais e sua morfologia. Uma das principais funções da metalografia é a de identificar os microconstituintes presentes na microestrutura de determinados materiais metálicos. Entender as características microestruturais de um material é essencial para garantir sua qualidade, a partir da correlação entre processamento-estrutura-propriedade, o que possibilita o design e seleção corretos de materiais existentes, além do desenvolvimento de novos materiais (DUTTA *et al.*, 2019). Diversos fatores de processamento influenciam a formação dos microconstituintes, como os tratamentos térmicos, tratamentos mecânicos, processos de fabricação, entre outros processos aos quais o material possa ter sido submetido. Por sua vez, a presença e morfologia dos microconstituintes podem afetar diversas propriedades do produto final, sendo extremamente importante conhecer a microestrutura de um material a fim de determinar ou certificar sua aplicação. A identificação e quantificação dos microconstituintes presentes em um material permite a previsão de importantes propriedades do mesmo, como dureza e resistência à fadiga. A identificação de microconstituintes consiste em uma análise qualitativa. Já a quantificação dos microconstituintes é uma análise quantitativa, que pode empregar diversas técnicas, como a análise linear, análise de área e estereologia. Estas análises podem ser efetuadas de maneira manual, completamente dependente da ação de humanos, ou de maneira digital, podendo ser semi ou totalmente automatizadas.

A utilização de ferramentas digitais de análise de imagens metalográficas é relativamente atual, marcada pelo surgimento das primeiras máquinas comerciais na década de 70, como o Quantimet 720 ou Texture Analysis System (TAS). Na época, estas máquinas eram muito caras, com preço similar ao de um microscópio eletrônico de varredura (MEV). O progresso na tecnologia da computação, principalmente na década de 90, com a popularização do *personal computer* (PC, computador pessoal), permitiu o desenvolvimento de softwares de análise de imagens mais acessíveis. Atualmente, a informática dos materiais, produto da união entre a tecnologia da informação e a ciência de dados, viabiliza a interpretação e análise de dados metalográficos em larga escala, potencializando e acelerando a

descoberta, design e processamento dos materiais. Mesmo que os avanços tecnológicos nos últimos anos sejam inegáveis, ainda é encontrada muita resistência quanto à utilização de ferramentas digitais/automáticas nos laboratórios metalográficos (WOJNAR; KURZYDŁOWSKI; SZALA, 2004; CHOWDHURRY *et al.*, 2016).

Apesar da resistência, a análise automática de imagens é quase que um pré-requisito no controle de qualidade de materiais, pois reduzem a subjetividade das análises humanas/manuais, permitem reprodutibilidade dos métodos e experimentos empregados, aceleram os processos de análise (importante em processos industriais), possuem baixo custo relativo (considerando uso frequente) e facilitam a documentação dos resultados. Além disso, sabe-se que erros humanos na classificação de imagens em geral acontecem com certa frequência, dadas as condições de fadiga e cansaço ou descuido e desatenção, comuns em atividades repetitivas. Dessa forma, a automação de processos de avaliação de imagens microestruturais deve ser fortemente considerada se atende as seguintes condições: o laboratório consegue garantir amostras de boa qualidade; há um domínio de análises de rotina sob de investigação de casos atípicos; e se a alta reprodutibilidade e velocidade das análises são fatores importantes (WOJNAR; KURZYDŁOWSKI; SZALA, 2004). As análises quantitativas são mais facilmente automatizadas que as qualitativas, o que pode ser explicado justamente por serem mais suscetíveis a erros quando executadas por humanos. Já as análises qualitativas automatizadas são menos difundidas na indústria, pela dificuldade em se obter imagens de qualidade adequada e de desenvolvimento de algoritmos eficazes, problemas inexistentes na classificação realizada por pessoas capacitadas, dada a natureza nativa do reconhecimento de padrões na mente humana.

A partir do contexto atual de análise digital de imagens metalográficas, a proposta deste trabalho é de desenvolver uma aplicação acessível e que atinja bom discernimento das principais microestruturas encontradas em aços, através do uso da inteligência artificial da IBM (Watson™), provando a aplicabilidade de ferramentas de automação na classificação qualitativa de microestruturas. O caso de uso para a base deste trabalho é a criação de uma ferramenta de suporte acadêmico para alunos universitários, principalmente dos cursos de engenharia metalúrgica ou de materiais ou de ciência dos materiais. Será utilizado o serviço Watson™ Visual

Recognition, da IBM, que permite a criação de modelos de reconhecimento visual através de algoritmos robustos de *deep learning*.

1.1 OBJETIVOS

O objetivo deste trabalho é desenvolver uma aplicação capaz de reconhecer as principais microestruturas presentes em aços, analisando imagens enviadas pelos usuários da aplicação. Espera-se que seja possível obter uma alta precisão e confiabilidade nos resultados da aplicação.

A aplicação será desenvolvida com tecnologias da IBM, com intuito de investigar sua usabilidade como ferramenta no campo de micrografias, desde a montagem do modelo de classificação até sua possibilidade de integração com outros sistemas, criando uma interface com os usuários finais. Dessa forma, será utilizada uma abordagem de ponta a ponta na elaboração da aplicação. Contudo, por se tratar de uma análise investigatória, foi selecionado um caso de uso de suporte acadêmico para alunos universitários, que possam se beneficiar da ferramenta em seus estudos. Deseja-se obter acurácia de classificação superior a aleatória.

2 REVISÃO BIBLIOGRÁFICA

2.1 MATERIAIS DE INTERESSE

Para o desenvolvimento deste trabalho, foi preciso limitar os tipos de materiais que serão estudados, para que sejam atingidos com a aplicação, índices de precisão e confiabilidade adequados. Dessa forma, foram considerados apenas as ligas de ferro, especialmente os aços.

2.1.1 Ferro

O ferro (Fe) é um elemento metálico, encontrado no estado sólido a temperatura ambiente. É um metal tenaz e maleável, despertando o interesse da indústria por sua dureza e baixo custo, apesar de oxidar facilmente (WINTER, 1993). É um dos cinco elementos mais abundantes da crosta terrestre, sendo superado apenas pelo oxigênio, silício e alumínio. A tabela abaixo retrata os dez elementos mais abundantes na crosta terrestre:

Tabela 1 – Abundância dos Elementos na Crosta Terrestre

Elemento	Símbolo	Abundância na crosta terrestre (%)
Oxigênio	O	46,1
Silício	Si	28,2
Alumínio	Al	8,23
Ferro	Fe	5,63
Cálcio	Ca	4,15
Sódio	Na	2,36
Magnésio	Mg	2,33
Potássio	K	2,09
Titânio	Ti	0,57
Hidrogênio	H	0,14

Fonte: Adaptado da tabela “ABUNDANCE OF ELEMENTS IN THE EARTH'S CRUST AND IN THE SEA” (LIDE, 2005, p. 2373)

Apesar de sua abundância, o ferro raramente é encontrado em sua forma metálica, sendo explorado através da extração de minérios e posterior conversão em ferro metálico, através de processos de redução. Os minérios de ferro podem ser classificados de acordo com a composição química do mineral fornecedor do elemento metálico, sendo os mais comuns: óxidos, carbonatos, sulfetos e silicatos. Contudo, apenas a exploração dos óxidos tem expressão econômica para a obtenção do ferro (DE CARVALHO *et al.*, 2014). Os principais minerais de minério de ferro são: Magnetita (conteúdo teórico de 72,4% de ferro em sua composição), Hematita (69,9%) e Goethita (62,9%), todos óxidos. Quanto maior o teor de ferro no minério, mais adequado é seu uso para a aciaria.

Ainda de acordo com De Carvalho *et al.* (2014), a maior parte da demanda por minérios de ferro vem justamente da aciaria: a produção de aço representa mais de 90% da demanda. A abundância deste minério na crosta terrestre é um dos principais motivos que alavancou o aço como um dos materiais mais importantes nas últimas duas décadas.

2.1.2 Aço

Os aços compõem uma das principais famílias de ligas à base de ferro, sendo amplamente utilizadas. Um dos principais elementos de liga associado ao ferro é o carbono, cuja adição ao ferro já é suficiente para que se forme um aço, promovendo um aumento da resistência do ferro (HONEYCOMBE, 1981). Segundo Colpaert (2008), uma das características mais importantes que diferencia os aços dos ferros fundidos, outra importante família de ligas de ferro, é sua capacidade em serem deformados plasticamente. A maleabilidade dos aços também é tida como sua principal característica, de acordo com Scheer (1987, p. 1): “aços são ligas maleáveis de ferro”.

Os aços ganharam importância dentre os materiais industriais por diversos fatores, além da abundância de ferro encontrado na terra. Seu custo de produção é relativamente baixo em usinas modernas, possuem combinações desejáveis de propriedades físicas e químicas e uma ampla gama de aplicações, desde na construção civil e no setor automobilístico até utensílios de cozinha. Ainda, destacam-se seus benefícios no quesito sustentabilidade.

Atualmente, os aços são especialmente valorizados, também pela facilidade de serem reciclados, pela vida relativamente curta quando descartados e pelo consumo específico de energia relativamente baixo em sua produção, fatores que levam a sua caracterização como material de elevada “sustentabilidade” (COLPAERT, 2008, p. 3).

O processamento dos aços permite a manipulação das características dos mesmos, levando a diferentes combinações das propriedades físicas e químicas, sendo cada uma dessas favorável à determinada aplicação. Os procedimentos de fabricação do aço compreendem a redução do minério de ferro para obtenção de uma liga bastante impura, denominada ferro gusa, o refino do ferro para reduzir o teor de impurezas indesejadas e a adição de elementos de liga para melhoria de propriedades, operações estas feitas na aciaria. O processamento de minério de ferro em altos-fornos é o principal processo na metalurgia do ferro, promovendo a redução dos óxidos dos minérios de ferro através da utilização de materiais ricos em carbono, como o carvão. O carvão serve de combustível para que a temperatura ideal para redução seja atingida, e, ao mesmo tempo, fornece carbono formando uma liga, chamada de ferro-gusa, posteriormente encaminhada para os processos de aciaria, ainda em estado líquido (CHIAVERINI, 1986).

O principal componente dos aços é o ferro, mas outros elementos podem estar presentes para conferir ao material determinadas propriedades. É o caso de elementos como carbono, silício, manganês, cromo, níquel, etc. O carbono e o silício acompanham naturalmente o ferro devido a sua presença nos minérios, mas também podem ser adicionados ao ferro durante seu processamento, se necessário. Porém, tais elementos, quando presentes em altos teores, pioram a maleabilidade do material. Se o carbono for adicionado em teores maiores que 2% em peso, o material recebe o nome de ferro fundido (SCHEER, 1987).

Pode-se definir o aço como uma liga de ferro-carbono, onde o teor de carbono não ultrapassa 2% em massa. Este limite está associado com a solubilidade do carbono no ferro de estrutura cristalina CFC (cúbica de face centrada). Contudo, a adição de elementos de liga pode alterar este limite de solubilidade, sendo esta definição mais adequada aos aços carbono. O ferro fundido compreende as ligas de ferro com mais de 2% de carbono. Estas ligas apresentam ponto de fusão mais baixo e por isso são adequadas aos processos de fundição (COLPAERT, 2008).

As mudanças de propriedades dos aços têm extrema dependência da estrutura na qual o ferro se organiza no material, ou seja, sua fase. As fases encontradas no sistema binário Fe-C persistem em aços mais complexos, contudo, os demais elementos de liga influenciam na formação e propriedades dessas fases (HONEYCOMBE, 1981).

2.2 PRINCIPAIS FASES DOS AÇOS

A preparação de aços envolve a fusão do ferro e adição de elementos de liga e de fundentes que forneçam o carbono necessário para produzir um material com as propriedades adequadas. A quantidade dos elementos (composição química), em conjunto com a taxa e temperatura de resfriamento, produzem diversas combinações de fases, que compõem a microestrutura do material produzido. O arranjo das fases pode produzir materiais com diversas propriedades. Dessa forma, as características da microestrutura são capazes de influenciar nas propriedades do aço, tornando seu conhecimento muito importante.

Segundo Colpaert (2008), as fases são porções homogêneas de um sistema, cujas características dependem do estado físico, da estrutura cristalina dos componentes e da composição química. A estrutura cristalina é determinada pelo arranjo e interação entre os átomos do material. Estes arranjos sofrem alterações conforme outros elementos são adicionados ao material, afetando a estabilidade dos arranjos. Assim, a adição de carbono ao ferro provoca alterações na estabilidade relativa entre as fases do metal. A estabilidade relativa das diferentes fases pode ser avaliada através de um diagrama de equilíbrio ou diagrama de fases, onde descreve-se qual delas é mais estável à determinada temperatura em função da variação da composição química da liga. O diagrama é dito binário quando são consideradas as interações entre somente dois elementos.

As principais fases encontradas nas microestruturas de aços carbono (Fe-C) são descritas pelo diagrama de fases binário do ferro e carbono, principais constituintes dos aços. A Fig. 1 representa o diagrama de equilíbrio de fases Fe-C, onde na abcissa pode ser lido a porcentagem de carbono presente em massa, e na ordenada, a temperatura. O diagrama de fases é um mapa termodinâmico que

informa o domínio de estabilidade das diferentes fases para pares de valores composição – temperatura.




Figura 1 – Diagrama de equilíbrio metaestável de fases binário Fe-C

Fonte: (HANSEN, 1958, p. apud. HONEYCOMBE, 1981, p. 50)¹. Extraído de Aços – Microestrutura e propriedades (HONEYCOMBE, 1981).

¹ Hansen, Constitution of Binary Alloys, 2ª ed., McGraw Hill, 1958.

O ferro apresenta mais de uma forma alotrópica com estruturas cristalinas estáveis à pressão ambiente (1 atm), desde a temperatura ambiente até a temperatura de fusão. As estruturas cristalinas assumidas pelos átomos de ferro puro são a CCC (cúbica de corpo centrado) e CFC (cúbica de face centrada). Até 910°C, o ferro assume estrutura CCC, que corresponde à fase ferrita (ferro- α). Acima desta temperatura até 1394°C, a estrutura mais estável é a CFC, correspondente à austenita (ferro- γ). A partir de 1394°C até a temperatura de fusão de 1535°C, o ferro volta a exibir uma estrutura CCC, chamada de ferrita (ferro- δ) (COLPAERT, 2008).

Alguns pontos críticos deste diagrama (Fig. 1) devem ser destacados. O primeiro é o ponto eutetóide, que corresponde à temperatura de 723°C e teor de carbono de 0,8%, onde ocorre a reação eutetóide (S). A reta P-S corresponde à temperatura A1 de transição entre ferrita e austenita e a reta S-K de transição entre a cementita e a austenita. Em seguida, tem-se o ponto A2, também conhecido como ponto de Curie, cuja temperatura é de 769°C. Neste ponto, ocorre uma transformação que não reflete em uma mudança de estrutura cristalina, porém, causa alterações nas propriedades magnéticas: o ferro deixa de ser ferromagnético e torna-se paramagnético. Segundo Scheer (1987), antigamente, nomeavam-se o ferro ferromagnético como ferro- α e o paramagnético, encontrado entre as temperaturas A2 e A3, como ferro- β . O ponto A3 corresponde à mudança do ferro- α para o ferro- γ , que ocorre à 910°C. Quando se adiciona carbono, esta temperatura torna-se gradativamente menor. Por fim, o ponto A4 corresponde à mudança do ferro- γ para ferro- δ , que ocorre acima de 1390°C. A adição de carbono causa o aumento gradativo desta temperatura (HONEYCOMBE, 1981).

Existem outras fases importantes que não são exibidas no diagrama (Fig. 1), por este se tratar de um diagrama em equilíbrio metaestável, e algumas das fases em questão serem encontradas apenas em equilíbrios estáveis. Ainda, o diagrama da Fig. 1 Está reduzido a até 5% de carbono em massa, sendo algumas fases encontradas apenas com teores maiores do elemento. A figura abaixo ressalta as diferenças entre os diagramas de fases em equilíbrio metaestável e estável.




Figura 2 – Diagramas de fase Fe-C metaestável (a) e estável (b)

Fonte: Extraído de Metalografia dos aços (TSCHIPTSCHIN, GOLDENSTEIN e SINATORA, 1988, p. 51).

O equilíbrio estável (Fig. 2b) dificilmente é estabelecido em aços, de forma que não se observa a formação da fase grafita. No equilíbrio metaestável, ao invés da grafita, forma-se a fase Fe₃C (carboneto de ferro), chamada de cementita.

Além das fases, devem-se considerar também os microconstituintes, ou seja, estruturas formadas por mais de uma fase, como é o caso da perlita. A tabela abaixo traz as principais fases e microconstituintes dos aços de maneira resumida. Estes componentes serão tratados com mais detalhes nas seções a seguir.

Tabela 2: Principais fases e microconstituintes encontrados no equilíbrio Fe-C

Fase / [Microconstituente]	Estrutura Cristalina
Ferrita (ferro- α)	CCC (cúbica de corpo centrado)
Ferrita (ferro- δ)	CCC (cúbica de corpo centrado)
Austenita (ferro- γ)	CFC (cúbica de face centrada)
Cementita (Fe ₃ C)	Ortorrômica
[Perlita]	-
Martensita	TCC (tetragonal de corpo centrado)
[Bainita]	-
Grafita	Hexagonal

Fonte: Adaptada da tabela "TABLE 1 IMPORTANT METALLURGICAL PHASES AND MICROCONSTITUENTS" (ERICSSON, 1995, p. 15).

2.2.1 Ferrita

2.2.1.1 Ferro- α

A ferrita é uma fase estável que pode ser encontrada no ferro puro ou em aços que contenham baixos teores de carbono, abaixo do limite de solubilidade da cementita na fase CCC. Nestes casos, o material é essencialmente monofásico, apresentando apenas a fase CCC, ou seja, a ferrita, na temperatura ambiente. A dureza destes materiais é baixa, favorecendo seu uso em aplicações como anéis de vedação metal-metal, onde é esperada uma deformação que permita o ajuste na conexão para que se obtenha a vedação (COLPAERT, 2008).

Os contornos de grãos percebidos na ferrita são mais irregulares. Nas imagens metalográficas, não há distinção de coloração, devido às orientações diversas dos grãos (TSCHIPTSCHIN; GOLDENSTEIN; SINATORA, 1988). De acordo com Colpaert (2008), se o resfriamento do aço a partir do campo austenítico for relativamente lento, é possível obter grãos equiaxiais de ferrita. Contudo, o trabalho a frio pode promover a deformação do aço e a mudança da forma dos grãos.




Figura 3 – Microestrutura da ferrita (α)

Fonte: Extraída de ASM Metals Handbook v. 9 - Metallography and Microstructures (ASM INTERNATIONAL, 2004).

É importante destacar os elementos que favorecem a formação da ferrita, pois existem diversos elementos de liga que podem estar presentes nos aços. Os principais estabilizadores da ferrita são: silício (Si), cromo (Cr), fósforo (P), molibdênio (Mo), vanádio (V), titânio (Ti), nióbio (Nb) e, por fim, alumínio (Al). Todos estes elementos, com exceção do alumínio, possuem estrutura cristalina CCC quando puros (COLPAERT, 2008).

2.2.1.2 Ferro- δ

A ferrita (ferro- δ) possui um domínio bastante restrito na maioria dos aços, sendo encontrada apenas entre 1390 e 1534°C, com um teor máximo de carbono de 0,5% (HONEYCOMBE, 1981). O ferro- α e ferro- δ representam a mesma estrutura (CCC), porém ocorrem em diferentes faixas de temperatura. No ferro- δ , a solubilidade máxima do carbono é maior, por conta da elevada temperatura em que esta fase ocorre, o que favorece a dissolução do carbono por conta da agitação térmica da matriz de ferro (ROLLO, 2015).

2.2.2 Austenita

A austenita é a fase estável com estrutura cristalina CFC. Nesta fase, a solubilidade do carbono no ferro é maior do que quando comparada à ferrita (SCHEER, 1987).

Os elementos que favorecem a formação da austenita são aqueles que, em geral, possuem estrutura cristalina CFC em seu estado puro. Dessa forma, os principais estabilizadores da austenita são: níquel (Ni), manganês (Mn), carbono (C), cobalto (Co), cobre (Cu) e nitrogênio (N) (COLPAERT, 2008).

2.2.3 Cementita

A cementita é o nome dada à fase cerâmica que representa o carboneto de ferro (Fe_3C), cuja estrutura cristalina é ortorrômbica, com célula unitária complexa, formada por 49 átomos por célula. É uma fase metaestável muito dura e relevante

para o comportamento da maioria dos aços. A presença de cementita nos aços promove aumento de dureza com prejuízo de sua tenacidade. Sua formação ocorre devido a grande diferença de solubilidade do carbono na fase ferrita alfa e austenita, o que provoca sua precipitação como carboneto de ferro quando os limites da fase gama são atingidos (HONEYCOMBE, 1981). Diversos elementos podem formar carbonetos estáveis nos aços, ou mesmo se dissolverem na cementita. É o caso de cromo (Cr), tungstênio (W), vanádio (V), titânio (Ti), nióbio (Nb) e molibdênio (Mo) (COLPAERT, 2008). A figura a seguir mostra a morfologia da cementita:




Figura 4 – Filme de cementita nos contornos de grãos perlíticos em um aço hipereutetóide

Fonte: Imagem obtida da biblioteca de imagens metalográficas Dissemination of IT for the Promotion of Materials Science (DoITPoMS) (UNIVERSITY OF CAMBRIDGE, 2018).

2.2.4 Perlita

O diagrama Fe-C apresenta uma reação eutetóide que ocorre a 723°C. As fases envolvidas nesta reação são a austenita, a cementita e a ferrita. A transformação da austenita para cementita e ferrita requer uma grande movimentação do carbono. Assim, ocorre um crescimento cooperativo entre a ferrita

e a cementita, em placas paralelas das duas fases, chamadas de lamelas, que seguem a mesma orientação. Esta fase de aspecto lamelar e de composição heterogênea é chamada de perlita. Pode-se dizer que a perlita é um compósito, com matriz dúctil (ferrita) e um reforço de alta dureza (cementita). Por isso, tem alta dureza e elevada resistência mecânica e ao desgaste, além de razoáveis resistência à fadiga e tenacidade à fratura (COLPAERT, 2008). Segundo Honeycombe (1981, p. 53), “a perlite² [perlita] não é uma fase, mas sim uma mistura de duas fases [cementita e ferrita]”.

A transformação da austenita para perlita tem início nos contornos de grãos austeníticos, onde formam-se núcleos de cristalização de cementita e ferrita. As placas crescem lado a lado para o interior do grão de austenita, sendo o transporte do carbono facilitado pela proximidade das lamelas. A perlita apresenta um brilho de madrepérola no estado polido ou atacado, sendo essa a origem do nome desse microconstituente (sendo “*mother of pearl*” o termo em inglês, levando ao nome *pearlite*) (SCHEER, 1987). A Figura 5 mostra o microconstituente perlita em um aço de composição eutetóide:




Figura 5 – Perlita em aço eutetóide

Fonte: Figura 13 (BHADESHIA, 2008).

² do inglês “*mother of pearl*” devido à coloração iridescente

2.2.5 Martensita e Bainita

Tanto a martensita quanto a bainita são formadas a partir do rápido resfriamento da austenita. A bainita é um microconstituente metaestável formado quando a austenita é rapidamente resfriada e mantida a temperaturas dentro da faixa de 200 a 400°C. Caracteriza-se por ser uma dispersão de carbonetos submicroscópicos em uma matriz acicular, mostrada na Figura 6.




Figura 6 – Bainita

Fonte: Figura 9a. (BHADESHIA, 2005).

Já a martensita é formada com o resfriamento rápido da austenita a temperaturas menores que as de formação da bainita. É uma fase metaestável muito dura e frágil, onde o carbono encontra-se aprisionado em solução sólida supersaturada e seu excesso provoca a distorção da estrutura cristalina, tornando-a tetragonal de corpo centrado (TCC). As transformações da austenita são controladas pela velocidade de difusão dos componentes, bem como do tempo e temperatura de reação. Porém, a transformação em martensita é uma exceção: ocorre sem difusão e muito rapidamente (quase independente do tempo). Essa transformação ocorre por um mecanismo de cisalhamento (semelhante ao mecanismo de maclação mecânica). Quanto menores as temperaturas, maior a fração de austenita que se transforma em martensita (CETEC, 2007).

A martensita apresenta diferentes morfologias em aços de baixo e alto carbono. Nos aços baixo carbono, a martensita apresenta feixes de ripas agrupadas. As ripas de um mesmo feixe são paralelas e entre os feixes há uma angulação de 60° , o que justifica os arranjos triangulares observados após o polimento, conforme mostrado na Figura 7.




Figura 7 – Martensita em ripas em aço baixo carbono

Fonte: Figura 5a (KITAHARAA, UEJI, et al., 2006, p. 1284)

Já para os aços de alto carbono, a martensita se apresenta em plaquetas com forma tridimensional de lentes. Esta morfologia é chamada de martensita acicular, pois as plaquetas assumem forma de agulhas no plano da superfície polida. O interior das plaquetas é marcado por maclas, que podem ser observadas no Microscópio Eletrônico de Transmissão (MET) (TSCHIPTSCHIN; GOLDENSTEIN; SINATORA, 1988). Esta morfologia também recebe o nome de martensita em placas.




Figura 8 – Martensita em placas em liga Fe-C com 1,86% em peso de C

Fonte: Figura 2.1b (YEDDU, 2012, p. 3)

2.2.6 Grafita

A grafita é uma das formas alotrópicas do carbono, cuja estrutura cristalina é hexagonal. Para que houvesse formação da grafita em aços, a taxa de resfriamento deveria ser muito lenta, o que não ocorre na indústria, por isso a grafita não é encontrada nos aços. Em seu lugar, é formada a cementita, que é metaestável. Apesar disso, a cementita praticamente não se decompõe em grafita a temperatura ambiente, pois a taxa de difusão do carbono no ferro é muito baixa, podendo assim ser considerada estável nessas condições (ROLLO, 2015).

2.3 COMPUTAÇÃO COGNITIVA

A matemática acompanhou o desenvolvimento dos humanos desde as eras mais antigas até os dias de hoje, estando presente em muitos campos de interesse, dentre eles, a computação. Muitos instrumentos foram utilizados para facilitar os cálculos matemáticos, como os ábacos (datados de 2700 – 2300 a.C.), utilizados em

diversas partes do mundo, com variações em sua forma. Outros instrumentos foram criados com o passar dos anos, como os bastões de John Napier, no século XVI. No século seguinte, foram desenvolvidas máquinas mecânicas capazes de realizarem cálculos, sendo a mais conhecida destas a “Calculadora de Pascal” ou “Pascalina”, concebida pelo matemático Blaise Pascal. A ideia de que a inteligência humana poderia ser potencializada através de instrumentos e ferramentas motivava os avanços dos equipamentos de cálculos. Já no início do século XIX, em meio à Revolução Industrial, o mecânico francês, Joseph Marie Jacquard, inventou um tear mecânico controlado por cartões perfurados (colunas e linhas de orifício em padrões diversos), onde ganchos das engrenagens tocavam os cartões e produziam diferentes desenhos têxteis de acordo com o padrão de orifícios. Essa máquina não representa um instrumento puramente matemático, mas sua concepção permitiu uma produção mais acelerada e com menores erros, quando comparada à manufatura humana. Ainda no século XIX, Charles Babbage e Ada Lovelace trabalharam no “Calculador Analítico”, um projeto que se assemelhava muito às funções desempenhadas pelo computador nos dias de hoje. Contudo, o projeto não foi terminado por conta da tecnologia da época e esgotamento dos fundos. No final do século, Herman Hollerith desenvolveu uma tecnologia baseada na de Jacquard e de Babbage, porém contava com uma ferramenta que os antecessores não tiveram acesso: a eletricidade. O projeto de Hollerith foi utilizado para tornar mais rápida a contagem da população para o censo demográfico dos EUA. Com a máquina de Hollerith, os funcionários realizavam a leitura dos dados do censo e perfuravam cartões nos lugares adequados para marcar características da pessoa cujos dados foram coletados. Estes cartões eram inseridos na máquina e pressionados por pinos. Os pinos atravessavam os orifícios presentes nos cartões e tocavam um metal no lado oposto, fechando um circuito elétrico e transmitindo um impulso aos contadores (MANEY; HAMM; O'BRIEN, 2011).

Dessa forma, percebe-se que a computação, até a metade do século XX, tinha como principal função realizar cálculos rapidamente. Contudo, a função dos computadores passou a mudar, com o desenvolvimento da capacidade de escrever e executar programas, motivada pela Segunda Guerra Mundial e a necessidade de encriptar mensagens. É neste contexto que o matemático britânico Alan Turing ganha destaque, com o desenvolvimento da máquina “*the Bombe*”, para decodificar mensagens enviadas pelos alemães nazistas (FONTOURA, 2013). A partir desse

momento, os computadores programáticos entraram em foco, devido sua capacidade de adaptação a diversos cenários, como o processamento de dados de empresas ou a computação pessoal, permitindo também o desenvolvimento de uma rede global de informações (CAMPBELL-KELLY, 2009). Os sistemas programáticos ainda estão muito presentes nos dias de hoje, onde computadores tradicionais são programados para executar determinadas tarefas, como é o caso de aplicativos e de *games* (JIMENÉZ, 2015).

Porém, temos presenciado na última década, uma geração de dados muito alta, devido à internet e à amplificação de seu uso. Os sistemas computacionais programáticos não estão preparados para lidar com esse volume extremo de dados, principalmente quanto à adaptação de suas respostas às tendências percebidas nas informações coletadas. Nas palavras de Jiménez (2015): “as duas primeiras fases da computação — a estática e a dinâmica — deram lugar a uma terceira: a autônoma”. É neste contexto que surgem os sistemas cognitivos.

Os sistemas cognitivos representam uma mudança no paradigma de sistemas computacionais, pois é proposto que os usuários deixem de se preocupar com a maneira como o sistema opera e passem a fornecer dados e informações para que o sistema cognitivo possa interpretá-los e compreender os usuários, gerando respostas com o teor de *insights*. Os sistemas cognitivos são capazes de se aperfeiçoar a cada dia, tornando-se mais precisos com base nas informações as quais tem acesso. Isto é possível devido aos modelos matemáticos empregados na concepção destes sistemas, como algoritmos de *Machine Learning* e *Deep Learning*, que serão discutidos a seguir.

2.3.1 Machine Learning

Machine Learning (ou Aprendizado de Máquina) consiste, basicamente, em artifícios matemáticos que permitem a capacidade de compreender e reconhecer padrões. Os algoritmos de *machine learning* são base para o funcionamento da Inteligência Artificial e tornaram possível o desenvolvimento de aplicações denominadas "cognitivas", que imitam o comportamento e/ou a cognição da mente humana. Isto ocorre, pois, o aprendizado de máquina confere aos sistemas

capacidade de adaptação a novas circunstâncias e de detecção e extrapolação de padrões (RUSSELL; NORVIG, 1995).

Os algoritmos de *machine learning* são capazes de aprender com os dados que lhes são submetidos e, através de treinamento, podem executar diferentes tarefas de maneira autônoma. Quando são expostos a um novo conjunto de dados, são capazes de se adaptar a partir dos cálculos anteriores e fornecem respostas cada vez mais confiáveis. Assim, a máquina passa a aprender as regras por conta própria, sem a necessidade de programá-las previamente. O fluxograma abaixo (Fig. 9) exemplifica as etapas de desenvolvimento genérico de um modelo de *machine learning*:

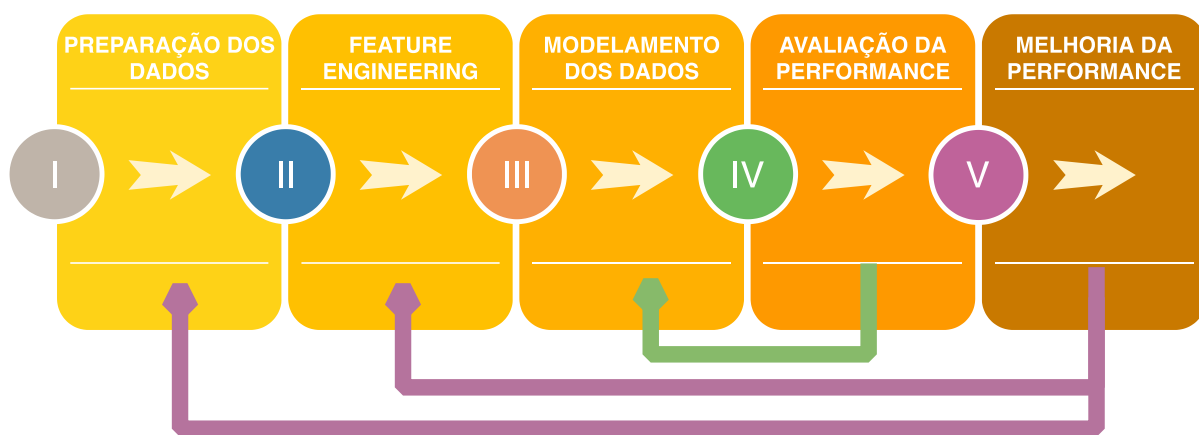


Figura 9 – Fluxograma de desenvolvimento de modelo de *machine learning*

Fonte: Adaptado de “What is a machine learning model?” (VESTUR, 2017, p. 6).

A primeira etapa é a preparação dos dados, onde deve-se buscar os dados a serem modelados, tomando-se o cuidado de remover dados incompletos ou tendenciosos. Em seguida, tem-se a etapa de *feature engineering* (engenharia de recursos), cujo objetivo é determinar propriedades isoladas que possam ser úteis ao modelo. A extração das características (*feature extraction*) ocorre nesta etapa. A próxima etapa é o modelamento dos dados, no qual deve ser escolhido o tipo de algoritmo a ser utilizado. O modelo fornecerá respostas (saídas), que serão avaliadas e utilizadas para refiná-lo. A quarta etapa é a de avaliação da performance do modelo, através de indicadores e métricas de qualidade bem conhecidos e do uso de dados de teste ainda não conhecidos pelo modelo, pois são separados da massa de treinamento. Por fim, tem-se a etapa de melhoria da performance, que

possui caráter iterativo e pode requerer alterações em qualquer uma das etapas do modelo (VESTUR, 2017).

Existem diversos tipos de algoritmos utilizados nas aplicações cognitivas, cada qual sendo aplicado de acordo com o problema a ser solucionado. No contexto atual, também deve ser destacado o algoritmo de *Deep Learning*, um dos algoritmos mais complexos dentro do domínio de *machine learning*.

2.3.1.1 Tipos de Algoritmos

De maneira geral, os algoritmos de *machine learning* podem ser classificados em três categorias, de acordo com a forma como o aprendizado ocorre. São elas: algoritmos supervisionados, algoritmos não supervisionados e algoritmos de reforço. Estes tipos de algoritmos, em conjunto com os principais exemplos dos mesmos, serão descritos nas sessões a seguir.

2.3.1.1.1 Algoritmos Supervisionados

Os algoritmos podem ser ditos como supervisionados se o conjunto de dados de treinamento da aplicação compreendem exemplos dos dados (vetores) de entrada, juntamente com os vetores alvo correspondentes, que são os dados esperados (e desejados) de saída para cada entrada (BISHOP, 2006). O modelo é preparado através de treinamento, onde realiza previsões e é corrigido pelo usuário caso esteja errado. O treinamento prossegue até que se atinja um resultado desejado de acurácia. Neste grupo de algoritmos estão os mais conhecidos, como regressão linear e classificação, além de regressão logística, árvore de decisões, *Random Forest* (Floresta Aleatória), entre outros (BROWNLEE, 2013).

2.3.1.1.2 Algoritmos Não Supervisionados

Os algoritmos são classificados como não supervisionados quando o conjunto de dados de treinamento contém apenas vetores de entrada, sem nenhum valor correspondente para os vetores alvo de saída. Estes algoritmos podem ser úteis quando se tem como objetivo identificar semelhanças entre os dados de entrada,

classificando-os em grupos – técnica chamada de *clustering* (agrupamento ou clusterização, em inglês). Também podem ser utilizados para identificar a distribuição dos dados no determinado espaço de entrada – técnica de *density estimation*, ou estimativa de densidade – além de outras técnicas (BISHOP, 2006).

2.3.1.1.3 Algoritmos de Reforço

Os algoritmos de reforço (cujo termo utilizado em inglês é *reinforcement*) têm como foco encontrar as ações adequadas a serem tomadas em determinada situação, para que se atinja o melhor resultado possível. Este tipo de algoritmo, diferentemente dos supervisionados, não recebe exemplos de saídas desejadas, mas sim, busca encontrá-las através de um processo de tentativa e erro (BISHOP, 2006).

2.3.1.2 Deep Learning

Deep Learning é um campo dentro de *machine learning*, onde são utilizados algoritmos mais robustos e mais rápidos. Os algoritmos de alto nível utilizam o princípio de redes neurais artificiais, que imita a rede neural do cérebro humano. Para isso, os dados passam por diversas camadas de processamento não lineares, simulando a forma humana de pensar, a partir dos neurônios. O *deep learning* tornou-se popular devido a sua alta capacidade de processamento, por isso, frequentemente está associado a *Big Data* – termo que representa o grande volume de dados envolvidos em processos complexos. Considerando o contexto atual de enorme capacidade de geração e coleta de dados, o *deep learning* é um dos algoritmos mais importantes nos dias de hoje. Uma de suas maiores aplicações diz respeito a tarefas de classificação, como os problemas de reconhecimento de imagens (SALESFORCE BRASIL, 2018).

2.3.2 Inteligência Artificial

A Inteligência Artificial (IA) é um conceito que vem ganhando extrema importância nas últimas décadas, ao se tratar de automação de tarefas repetitivas e de agilizar processos de decisão. Contudo, este conceito, um ramo da ciência da computação, permeia este campo desde seus primórdios. Apesar disto, o termo “Inteligência Artificial” só foi cunhado em 1956, na Conferência de Dartmouth, que pretendia estudar modos de trazer inteligência a computadores.

Uma das primeiras menções acadêmicas ao conceito de IA ocorreu em 1950, por Alan Turing, em seu artigo “*Can machines think?*” (“Máquinas podem pensar?”, tradução nossa). Neste artigo, Turing propõe um teste chamado de “jogo da imitação”, onde uma pessoa deveria interagir em forma de texto com duas entidades desconhecidas, sendo uma delas um computador. O objetivo é descobrir qual das duas entidades era representada pela máquina. Caso o computador pudesse imitar o comportamento humano tão bem que enganasse o participante, poder-se-ia dizer que o mesmo passou no “teste de Turing”. Apesar da grande contribuição ao campo da ciência da computação deixada por Turing, seu teste não foi tratado como um norte para o desenvolvimento de sistemas inteligentes. O “teste de Turing” seria adequado quando os sistemas devem interagir com pessoas, simulando um diálogo ou explicando ao usuário como obteve determinada resposta, pois, neste contexto, devem seguir regras e convenções normais da interação humana para se fazer entender. Porém, a representação e o raciocínio de certo sistema pode não ser baseado em modelos humanos, sendo o teste inadequado (RUSSELL; NORVIG, 1995).

Existem diversas definições que se aplicam à Inteligência Artificial. Em seu livro, Russel e Norvig (1995, p. 5) organizam as definições em quatro principais categorias: sistemas que pensam como humanos, sistemas que agem como humanos, sistemas que pensam racionalmente e sistemas que agem racionalmente. A Fig 10. ilustra as categorias descritas bem como as interligações entre os domínios que as compõem:




Figura 10 – Categorias de definições de Inteligência Artificial

Fonte: Autoria própria. Adaptado da figura "FIGURE 1.1 – SOME DEFINITIONS OF AI" (RUSSELL e NORVIG, 1995, p. 5)

A definição do termo Inteligência Artificial é motivo de grande discordância na comunidade científica. Isso ocorre pela definição difusa do conceito de inteligência. Coincidentemente, a categorização acima ignora o conceito de inteligência e utiliza aproximações com humanos e com a racionalidade para tipificar as diversas definições. De todo modo, existe um consenso entre os estudiosos do tema: humanos são diferentes de animais e máquinas essencialmente por sua habilidade mental (que pode ser chamada de inteligência), sendo a IA uma tentativa de reproduzir esta habilidade em sistemas computacionais (WANG, 2008).

Wang (2008) tipificou a IA em cinco definições de trabalho, para orientar estudos e pesquisas futuros. A primeira diz respeito à estrutura do cérebro humano, de onde supõe-se que a inteligência é originada. Nesta definição, IA pode ser alcançada pelo desenvolvimento de uma estrutura similar ao (ou pelo menos inspirada pelo) cérebro. A segunda é comportamental, semelhante à definição de Turing, onde a Inteligência Artificial é medida pela capacidade do sistema de se

comportar como uma pessoa. A terceira consiste na capacidade, principalmente de resolução de problemas complicados. Em seguida, tem-se o conceito de função, no qual a Inteligência Artificial é representada por um conjunto de algoritmos que imitam a cognição humana nas etapas de processamento de um problema. Por fim, o conceito de princípio define que sistemas de IA devem seguir princípios normativos semelhantes aos da mente humana.

De acordo com Russell e Norvig (1995), a Inteligência Artificial é um campo que tenta entender entidades inteligentes. Não só, a IA luta para criar entidades inteligentes, além de compreendê-las. Além disso, definem a Inteligência Artificial como um campo de estudo abrangente, que herdou ideias e técnicas de diversas outras disciplinas, como a filosofia, matemática, psicologia e linguística. Enquanto isso, a ciência da computação é tratada como a ferramenta capaz de tornar a IA uma realidade.

A Inteligência Artificial atualmente engloba uma enorme variedade de subáreas, desde domínios mais gerais, como a percepção e o raciocínio lógico, até tarefas mais específicas como jogar xadrez, provar teoremas matemáticos, escrever poesia e diagnosticar doenças (RUSSELL; NORVIG, 1995, p. 4).

Já para a IBM, o termo *Artificial Intelligence* (Inteligência Artificial, em inglês) é muitas vezes substituído por *Augmented Intelligence*, isto é, Inteligência Aumentada, pois a IA é vista como uma ferramenta que potencializa a inteligência humana, através do suporte, e não substituição nas tarefas e decisões realizadas por humanos. O objetivo é tornar as pessoas mais inteligentes, e não superar a inteligência humana. De todo modo, a visão de Inteligência Artificial da IBM para o IBM Watson®, que será discutido nas próximas seções, combina duas das categorias definidas por Russel e Norvig (1995), pois pretende que o sistema pense de maneira racional e aja de maneira semelhante à humana, interagindo com os usuários – pessoas – em seus termos. O sistema não é um modelo do cérebro humano, por isso, não pensa como um. A classificação nas categorias citadas acima é apoiada pelas palavras de David Ferrucci, pesquisador da IBM: “O objetivo é construir um computador que seja eficaz em compreender e interagir em linguagem natural, mas não necessariamente do modo que um ser humano faz” (MANEY; HAMM; O'BRIEN, 2011, p. 84).

O desenvolvimento da Inteligência Artificial está relacionado ao ambiente de informação na qual a mesma está inserida e ao qual deve se adequar. Atualmente, o contexto é de um ambiente totalmente dinâmico e continuamente em expansão, motivado pela popularização da Internet, pela permeação de redes de sensores, pelo surgimento de *Big Data* e pela associação e fusão de dados e informações simultaneamente através da sociedade humana, do espaço físico e do espaço virtual (PAN, 2016). Uma das maneiras de classificar diferentes tipos de dados diz respeito à sua forma: dados podem ser estruturados, semiestruturados ou não estruturados. Dados estruturados são predefinidos e podem ser facilmente encontrados em bancos de dados tradicionais. Os dados semiestruturados dificilmente apresentam conformidade com as especificações de bancos de dados, mas podem possuir estrutura adequada para atender determinadas aplicações. Já os dados não estruturados carecem da padronização necessária que permita seu gerenciamento e processamento eficientes através da computação tradicional. É o caso de dados de textos, fotos, áudios, vídeos e fluxos de cliques, gerados em um volume massivo por *e-commerces*, mídias e redes sociais e sensores (LEE, 2017). Um dos maiores desafios para a IA atualmente é a compreensão dos dados definidos como não estruturados, que representam a maior parcela dos dados gerados nesta última década.

Estimamos que 90% dos dados disponíveis no mundo hoje foram criados apenas nos últimos dois anos e que 80% deles são desestruturados, ou seja, são formatados como os humanos processam informação: blogs, tweets, artigos, papers, anotações médicas, etc. (RODRIGUES, 2014)

Ainda que a Inteligência Artificial seja um campo com definições controversas, seu potencial para apoiar novas tecnologias e ferramentas automatizadas é irrefutável. Nesse sentido, uma das premissas fundamentais é que a IA permite o desenvolvimento de tecnologias que se adaptam, configurando máquinas inteligentes – “[...] isto é, máquinas capazes de entender seu ambiente e modificar seu comportamento de acordo com o mesmo (adaptar), de forma a alcançar determinado objetivo” (CARAYANNIS, 1993, p. 1, tradução nossa). Existem diversas aplicações para a IA com alto potencial, dado o contexto atual de geração e digitalização de dados, de novos e poderosos algoritmos e de crescente potência computacional (duplicada a cada 18 meses). Exemplos de alto nível seriam a análise

de dados e a computação em nuvem (JIMENÉZ, 2015). Detalhando mais as aplicações, a IA pode ser útil na área da saúde, auxiliando médicos em seus diagnósticos ou na interpretação de exames; na área comercial, como na automação do atendimento ao cliente através de *chatbots* ou como assistente que indica os melhores produtos de acordo com o perfil do cliente; na área jurídica, buscando informações em longos documentos e tornando os advogados analistas mais eficientes e até mesmo na agricultura, com análises preditivas do clima em determinada região ou identificação automática de plantas em mau estado através de imagens coletadas por um drone. Muitas destes exemplos já podem ser realizados pelo Watson™, IA da IBM, que será detalhado abaixo.

2.3.2.1 IBM Watson®

A Inteligência Artificial da IBM é denominada de Watson™, nome que homenageia o primeiro CEO da empresa americana, Thomas J. Watson. Foi introduzida ao mercado em Fevereiro de 2010, após três anos de desenvolvimento onde se visava a criação de um sistema capaz de compreender a linguagem natural humana. Em Fevereiro de 2011, foram exibidos na rede americana de televisão por três dias, episódios especiais do programa *Jeopardy!* – uma competição de perguntas e respostas – onde antigos ganhadores do programa competiram com o Watson™, que vinha sendo desenvolvido e treinado desde meados de 2007. Watson™ acabou vencendo os outros dois competidores e o dinheiro arrecadado foi doado para instituições de caridade (MANEY; HAMM; O'BRIEN, 2011).



Figura 11 – Disputa de *Jeopardy!* entre Watson™ (no meio) e os campeões Ken Jennings (à esquerda) e Brad Rutter (à direita)

Fonte: Extraído de Tornando o Mundo Melhor: Ideias que moldaram um século e uma empresa (MANEY; HAMM; O'BRIEN, 2011, p. 83)

O Watson™ pode ser definido como um sistema de computador que pode ser aplicado em diversas situações, indo além de perguntas e respostas, englobando os sentidos humanos como visão, audição, fala, permitindo a leitura e interpretação de dados estruturados ou não.

Atualmente, o Watson™ é comercializado com foco em empresas, como um pacote de serviços, aplicativos e ferramentas de Inteligência Artificial prontos para uso³. Uma das principais vantagens listadas é a capacidade de aprender mais utilizando menos dados, o que será essencial para o desenvolvimento deste trabalho, pois a quantidade de dados com qualidade adequada é limitada.

Existem alguns casos de uso de sucesso utilizando o Watson™ que podem ser citados para exemplificar a relevância do mesmo para este trabalho.

³ Adaptado de IBM Watson: About, **IBM**. Disponível em: <<https://www.ibm.com/watson/about/index.html>>. Acesso em 7 jan. 2019.

2.3.2.1.1 Medicina: IBM® Watson Health™

A aplicação da Inteligência Artificial na medicina potencializa a capacidade diagnóstica e prognóstica dos médicos. Através de consultas a bancos de dados robustos, computadores são capazes de fornecer sugestões de diagnósticos, as quais podem confirmar hipóteses médicas, agilizando sua análise.

Existem também os dispositivos vestíveis/corporais (*wearable devices*), no qual a aplicação da Inteligência Artificial pode permitir a tomada de decisões automáticas, optando, por exemplo, por aumentar ou diminuir momentaneamente a dose de medicamentos.

Um famoso caso de sucesso do uso do Watson™ está em linha com o auxílio ao diagnóstico do profissional de medicina. Trata-se do Watson Health™, que processa diversas informações disponíveis na “nuvem” (*cloud*), sejam sobre a base de conhecimento médico ou sobre o histórico de pacientes, incluindo os sintomas, tratamentos e resultados.

Registrando um grande número de casos com seu esquema de diagnóstico, tratamentos prescritos e resultados obtidos, esses sistemas [Watson Health™, da IBM, e o Deep Mind, da Inglaterra] permitem uma expansão do conhecimento médico e a sugestão de condutas a serem seguidas, nesse caso com embasamento probabilístico (LOBO, 2017, p. 5).

Dentre as soluções do Watson Health™, encontra-se o Watson for Oncology, uma solução focada em câncer (atualmente, treinada em 13 tipos de câncer⁴), capaz de identificar, avaliar e comparar tratamentos disponíveis e mais adequados a cada paciente. Esta solução já é utilizada em mais de 270 hospitais e organizações de saúde, apresentando resultados expressivos, como o estudo divulgado na *Annals of Oncology* sobre o Hospital Manipal, onde os tratamentos sugeridos pelo Watson™ contra o câncer de mama apresentaram 93% de concordância com os escolhidos pela equipe médica especialista em tumores⁵.

⁴ De acordo com a página oficial da IBM: Watson Health: Get the Facts – Watson Health Perspectives, **IBM**. Disponível em <<https://www.ibm.com/blogs/watson-health/watson-health-get-facts/>>. Acesso em 7, jan., 2019.

⁵ Mais informações disponíveis em (SOMASHEKHAR *et al.*, 2018)

2.3.2.1.2 Otimização do processo de pré-vendas: Gerdau⁶

Este caso de uso é extremamente relevante, pois evidencia a modernização dos processos de pré-venda de aços, e a busca por novas tecnologias na área metalúrgica e de materiais.

O caso da Gerdau consiste no desenvolvimento de um *chatbot* cognitivo, ou seja, um robô capaz de interpretar as perguntas recebidas de uma forma semelhante a interpretação humana, fornecendo respostas mais precisas e um diálogo mais fluído. Este *chatbot* se tornou responsável pelo processo de pré-vendas de aços da Gerdau.

Antes de comprarem um aço, os clientes da Gerdau precisam realizar uma “consulta de fabricação”, onde é analisado se a Gerdau é capaz de atender às especificações técnicas do aço requerido. Os clientes precisavam preencher diversas informações sobre o tipo de aço desejado, através de um formulário extenso.

Hoje, utilizando diversos serviços da plataforma Watson™ da IBM, este processo foi otimizado. A IBM implantou um novo processo de consulta de materiais, leitura das características técnicas e varredura de dados na base da Gerdau, permitindo a recomendação do produto ideal que atenda as especificações do cliente, com um menor tempo de resposta quando comparado ao processo anterior.

Através das melhorias alcançadas com a implantação do Watson™ no processo de pré-vendas, foi possível otimizar o tempo total de atendimento de vinte para três dias, além de melhorar a experiência do cliente através da interação com o *chatbot*.

2.3.2.1.3 Reconhecimento de Imagens: IBM Watson® Visual Recognition e Volkswagen Virtus

O Virtus, carro modelo sedã da Volkswagen, é o primeiro carro a oferecer o chamado “manual cognitivo” aos motoristas. Com o uso de diversos serviços do Watson™, o manual é capaz de responder perguntas sobre o carro, interpretando a

⁶ As informações referentes a esta seção foram baseadas em
<<https://www.youtube.com/watch?v=NWu0jHP3nqo&feature=youtu.be>> (IBM BRASIL, 2018).

linguagem natural através da função de comando de voz. Já o Watson™ Visual Recognition, solução da IBM de IA que realiza o reconhecimento de imagens, é utilizado para identificar sinais do painel de controle. Por exemplo, se o motorista percebe uma luz amarela em seu painel, pode questionar ao manual cognitivo do Virtus o que o sinal significa e enviar uma foto através do próprio celular para que seja identificado o problema. O manual cognitivo retorna uma resposta em voz explicando a situação. Se o sistema não encontra informações para responder a questão, a Central de Relacionamento com o Cliente (CRC) da Volkswagen do Brasil é acionada e estabelece o contato com o cliente (ASSESSORIA DE IMPRENSA IBM BRASIL, 2017).

O domínio de reconhecimento de imagens e o Watson™ Visual Recognition serão tratados com mais detalhes nos próximos tópicos.

2.4 RECONHECIMENTO DE IMAGENS

O reconhecimento de imagens ocorre através de um domínio definido como reconhecimento de padrões: uma maneira complexa que o cérebro humano encontrou para classificar os mais diversos objetos e situações que encontra em seu cotidiano. Como afirmado por Richard, Hart e Stork (2012, p. 1, tradução nossa), “a capacidade de reconhecimento de padrões – o ato de coletar dados brutos e agir com base na categoria do padrão percebido – tem sido crucial para a sobrevivência humana”. Por isso, é natural que haja um interesse em construir máquinas capazes de reconhecer padrões com alta precisão, automatizando tarefas como o reconhecimento de digitais e sequenciamento de DNA. Contudo, a resolução de algumas dessas tarefas precisam considerar as maneiras como um ser humano lidaria com o problema abordado. De fato, percebe-se a importante associação entre o reconhecimento de padrões e as máquinas, mais especificamente, o aprendizado das mesmas, conforme explicitado por Bishop:

O reconhecimento de padrões tem suas origens na engenharia, enquanto o aprendizado de máquina cresceu a partir da ciência da computação. No entanto, essas atividades podem ser vistas como duas facetas do mesmo campo e, juntas, passaram por um desenvolvimento substancial nos últimos dez anos (BISHOP, 2006, p. vii, tradução nossa).

No âmbito computacional, o reconhecimento de padrões é um procedimento no qual se buscam determinadas estruturas nos dados de entrada, com base em estruturas já conhecidas. Em seguida, ocorre a classificação em categorias onde haja maior grau de associação entre as estruturas de entrada e as já conhecidas. A categorização é realizada por um classificador, que analisa as informações relevantes dos dados de entrada para prosseguir com a classificação. As propriedades que possibilitam o agrupamento de objetos semelhantes dentro de uma determinada classe ou categoria são chamados de padrões. As características são extraídas dos dados de entrada, a partir da qual os objetos são classificados. Já o termo classe pode ser definido como um conjunto de atributos comuns aos objetos de estudo (DE CASTRO; DO PRADO, 1999 - 2002).

Como nos modelos de *Machine Learning*, o reconhecimento de imagens também requer uma etapa de extração de características (*feature extraction*). Um exemplo de característica que poderia ser extraída para permitir o reconhecimento é a intensidade de luz, seus picos e vales. Porém, na extração de características, devem-se selecionar informações úteis a serem mantidas, já que partes das informações de entrada são descartadas (RICHARD; HART; STORK, 2012).

Existem fatores que dificultam o reconhecimento de imagens nas diversas etapas do processo de classificação, como a qualidade das imagens, que podem apresentar baixa resolução ou distorções. Outro grande empecilho é a etapa de segmentação, cuja função é identificar qual parte da imagem é realmente útil para a classificação, separando-a do plano de fundo ou isolando-a dos outros componentes da imagem (RICHARD; HART; STORK, 2012).

2.4.1 Aplicação no campo de Engenharia de Materiais e Metalúrgica

A aplicação de conceitos de reconhecimento de padrões no campo da Engenharia de Materiais e Metalúrgica vem sendo objeto de grande estudo na última década. Tradicionalmente, a avaliação de imagens de microestruturas é feita por pessoas especialistas, tanto na interpretação da micrografia quanto na conexão da mesma com condições de processamento e com as propriedades do produto final (DECOST; FRANCIS; HOLM, 2017). Atualmente, na área de engenharia metalúrgica, existe uma grande demanda de automatização do processamento de

imagens em larga escala, o que será útil para células de controle de qualidade de materiais, para estabelecer relações entre microestruturas e propriedades mecânicas e para projetar materiais com certas características desejadas (BULGAREVICH *et al.*, 2018). A fim de automatizar etapas dependentes de humanos, acelerando o processo de descoberta, design e desenvolvimento de materiais, muitos esforços vem sendo aplicados no campo de informática dos materiais, que une tecnologia e ciência de dados para analisar informações sobre determinados materiais (CHOWDHURRY *et al.*, 2016). A automação da identificação de diferentes morfologias de microestruturas a partir de métodos padronizados, transparentes e simples será capaz de apoiar o metalurgista em seu trabalho, eliminando a influência da percepção individual nos resultados da classificação (DUTTA *et al.*, 2019).

Em seu trabalho, Dutta *et al.* (2019) realizaram uma investigação primordial com objetivo de desenvolver um esquema simples de classificação de três tipos de morfologias microestruturais em um aço bifásico (*dual-phase*), cuja microestrutura era composta por ferrita e martensita. As três morfologias distintas foram obtidas através da aplicação de três tratamentos térmicos: recozimento intercrítico, têmpera intermediária e têmpera interrompida. Cada classe, representativa das três morfologias/tratamentos térmicos distintos, foi construída com 25 imagens para treinamento e 10 para testes. Quanto à metodologia de classificação, primeiramente foi realizada a binarização das imagens em uma escala de cinza através do algoritmo de Otsu, que garante diferenciação ótima entre os componentes presentes. Em seguida, a partir das imagens binarizadas, realizaram-se a etapa de extração de características (*feature extraction*) e, em seguida, a análise estatística das características extraídas. Foi empregado um algoritmo de extração que computa todos os comprimentos em pixels das classes brancas/pretas e o comprimento médio das mesmas. A classificação entre os três tipos de tratamentos térmicos estudados (as três classes consideradas) foi realizada através da determinação de uma faixa de comprimentos para cada classe, nas quais as imagens de testes serão tipificadas. Todas as imagens de testes analisadas foram corretamente classificadas, provando boa acurácia deste modelo.

A pesquisa de Bulgarevich *et al.* (2018) teve foco no desenvolvimento de um algoritmo do tipo *Random Forest* para segmentação das fases/microconstituintes e sua posterior comparação com a análise linear (feita manualmente). A segmentação

consiste em identificar os microconstituintes presentes em uma dada imagem, colorindo-os com cores diferentes. Foram obtidos bons resultados, próximos da classificação via análise linear. São apresentados como limitantes do algoritmo classificador o contraste, a escala da imagem e as fases/microconstituintes presentes. De acordo com os autores, apesar do atual foco na colaboração entre as áreas de informática e de materiais, ainda existem poucos estudos que abordam a utilização de processos de segmentação de imagens de microestruturas complexas com técnicas acuradas e automáticas, de modo que os resultados obtidos no trabalho são significativos. Apesar do potencial de automação, ainda é necessária a atuação de um especialista em microestruturas na demarcação das áreas representativas de cada microconstituente (porções de pixels), que é um processo vagaroso e que requer atenção e conhecimento. Além disso, a segmentação só poderá ocorrer entre micrografias que contenham exatamente o mesmo grupo de componentes apresentados na imagem de treinamento. Não foi tratada a criação de um aplicativo para viabilizar a utilização do algoritmo, mas foi sugerida a formação de bibliotecas de protocolos e bancos de dados para os padrões microestruturais típicos.

Outra referência interessante é o trabalho de Komenda (2001), que utilizou um software chamado Image Classifier para realizar o reconhecimento de microestruturas complexas em uma superliga de níquel e em um aço sinterizado FeCrMo. De acordo com o estudo, o Image Classifier foi aplicado na análise de imagens de satélites, identificando áreas de florestas, lagos e rochas automaticamente. Contudo, esta aplicação requereu o uso de diferentes tipos de luzes na coleta de imagens, como ultra e infravermelha, o que não seria possível em imagens metalográficas. Uma das limitações do programa Image Classifier é que as imagens de treinamento devem conter todas as classes que podem estar presentes na estrutura do objeto estudado, bem como serem produzidas nas mesmas condições que serão utilizadas nos processamentos futuros. Para que o Image Classifier possa identificar (e destacar) as fases presentes em uma imagem, além de calcular sua fração mássica, o usuário deve marcar na imagem de treinamento porções de pixels que representem determinadas fases com cores diferentes. Outro fator limitante é que o usuário deve ser capaz de identificar as fases com precisão e com o cuidado de selecionar todas as fases e microconstituintes presentes. A partir da imagem de treinamento, imagens denominadas “imagens características” (*feature*

images) são produzidas, isolando determinada característica da imagem original, como a saturação ou intensidade. Estas imagens características auxiliam a classificação feita pelo software, que retorna a imagem de treinamento completamente colorida, destacando as fases presentes de acordo com a tipificação obtida automaticamente.

Já DeCost, Francis e Holm (2017) prepararam um banco de dados de microestruturas com foco em estruturas complexas e hierárquicas, a partir de um aço de alto teor de carbono (UHCS) sob diversas condições de tratamentos térmicos. Foi discutido como algoritmos supervisionados ou não de *machine learning* podem contribuir para encontrar tendências nas microestruturas e relacioná-las com as condições de processamento. O estudo comparou a representação das microestruturas através dos métodos de *convolution neural networks* (CNN – redes neurais convolucionais) baseada em texturas e do método de *bag of visual words* (BoW). Para ambos, foram testados algoritmos supervisionados e não supervisionados. O banco de dados utilizados englobou 961 imagens de micrografias obtidas com SEM. Diversas microestruturas poderiam ser encontradas no banco, porém decidiram por, inicialmente, utilizar apenas três classes, com um total de 600 imagens originais (200 por classe), expandidas para 2400 imagens a partir de cortes nas originais, com dimensões de 224 x 224 pixels. Além da classificação das microestruturas complexas, também foi realizada uma classificação quanto a sequência de recozimento (13 possíveis sequências), baseando-se nas imagens com morfologia esferoidal (195 originais, 780 cortadas). Os resultados foram organizados em um mapa t-SNE (técnica não supervisionada) permitindo uma análise exploratória. A melhor combinação de algoritmos ocorreu com a CNN, alcançando acurácia superior a 95%. Ainda, os autores fizeram considerações para estudos futuros sobre a ciência de dados em microestruturas. O aspecto mais relevante é o de viés do banco de dados, que pode restringir a generalização do modelo para outros bancos e aplicações semelhantes. Este viés pode surgir na etapa de aquisição das imagens, devido a preparação das amostras e do processamento digital das imagens; na etapa de seleção das imagens, onde os especialistas tendem a focar em aspectos relevantes ou raros da microestrutura, por vezes ignorando visões representativas da amostra; e na etapa de anotação dos dados, que restringe principalmente os algoritmos supervisionados (que são limitados pela rotulagem humana).

No estudo de Chowdhury *et al.* (2016), foram utilizados diversos métodos de visão computacional e *machine learning* para classificar micrografias que continham dendritas. O classificador foi capaz de diferenciar morfologias dendríticas das não-dendríticas (tarefa 1), além de identificar a sessão de corte (longitudinal ou transversal – tarefa 2). As imagens coletadas variavam em escala, composição dos materiais e orientações microestruturais. Antes da aplicação dos algoritmos de *machine learning* na classificação das imagens, foi necessário extrair e selecionar características (*feature extraction* e *feature selection*). Para a etapa de *feature extraction*, foram utilizados diversos métodos, incluindo CNN pré-treinada, além outros algoritmos e modelos estatísticos. A utilização de uma rede neural pré-treinada permite que o banco de imagens seja bem menor do que os tradicionalmente utilizados em modelos de *deep learning*. Já a classificação utilizou outros algoritmos, como vizinhos próximos e *random forest*. Foram utilizadas 528 imagens para a tarefa 1 e 188 para a tarefa 2, com dimensões de 227 x 227 pixels. Os resultados indicam que a utilização de redes neurais pré-treinadas na etapa de *feature extraction* alavancam uma boa representação de imagens de microestruturas para a maioria das combinações com outros algoritmos nas etapas de seleção de características e classificação, atingindo acurácia máxima superior a 91 e 97% para as duas tarefas testadas.

Existem muitas variantes atuando sobre o campo das micrografias, como os processos de fabricação, a seção de corte do material (longitudinal ou transversal), as diversas técnicas de tratamento imagem (como contraste, luminosidade e níveis de RGB), as diferentes escalas, diferentes equipamentos e métodos de análise (TEM, SEM, microscopia óptica). Todas essas variáveis dificultam as tarefas de classificação, principalmente se o banco de imagens disponíveis é pequeno. Isto também reforça o quão desafiadora pode ser a etapa de organização do banco de imagens (CHOWDHURRY *et al.*, 2016). Além disso, imagens obtidas através de microscopia óptica podem apresentar ruídos que comprometem o processamento digital das mesmas (DUTTA *et al.*, 2019).

As pesquisas estudadas revelaram métodos que prometem reduzir ou remover a necessidade de análises de especialistas em microestruturas, previamente a outras etapas de análise (digital ou automatizada), o que diminui o viés na interpretação de imagens. No caso de análises quantitativas, como as estereológicas, esta consequência se destaca, pois ainda existe certa dependência de um especialista,

que deve primeiramente reconhecer características chaves na microestrutura (ex. inclusões, grãos ou fases), confiando em sua formação e experiência, o que pode gerar um viés. Contudo, nenhum dos estudos menciona a criação de um aplicativo ou software para estabelecer uma interface com o usuário final, dedicando maior foco nas técnicas de *machine learning* para elaborar modelos matemáticos de classificação que mais se adequem ao caso de uso (referente a microestruturas) estudado.

A partir das pesquisas estudadas, um conjunto de boas práticas foi explicitado, contudo, como não foram encontrados textos acadêmicos relacionando o uso do Watson em micrografias, outras referências foram procuradas para se determinar uma metodologia adequada para o desenvolvimento do *software* proposto neste trabalho.

3 METODOLOGIA E PLANO DE TRABALHO

3.1 METODOLOGIA SUGERIDA PARA PROJETOS DE INTELIGÊNCIA ARTIFICIAL

Projetos de diversas áreas envolvendo Inteligência Artificial estão cada vez mais comuns. Já é possível encontrar no mercado diversas empresas e *start-ups* que se dedicam a este tema.

As metodologias utilizadas na concepção de um sistema cognitivo são convergentes, com um fluxo de trabalho que permite o desenvolvimento dos sistemas simples até os mais complexos. Dessa forma, as pequenas variações apresentadas entre as metodologias apresentam-se mais no âmbito de exclusão de um dos passos – caso o mesmo não se aplique ao sistema proposto – do que na mudança de abordagem.

No geral, para desenvolver um sistema cognitivo, o ponto de partida consiste em identificar um problema que se deseja resolver. A solução para este problema é construída a partir de *insights* (percepções), os quais não são obtidos somente com os dados estruturados ou não disponíveis, mas sim com a aplicação de conhecimento aos dados, para extrair respostas que apresentem valor. Para isso, existe um componente chamado de módulo matemático, que regula as entradas e saídas do sistema, configurando a inteligência por trás da qual serão geradas as respostas. Este módulo conta com modelos matemáticos, compostos por algoritmos específicos, treinados de acordo com as características dos dados e do problema a ser solucionado. Posteriormente, o módulo é implementado em um *software*, a partir do qual é possível interagir com o sistema. A interação com os usuários do sistema é geralmente promovida por robôs chamados "*bots*" ou "*chatbots*", que se comportam de maneira aproximada à humana, criando um diálogo que integra as intenções do usuário com a resposta fornecida pelo sistema cognitivo.

De maneira mais detalhada, Alexandre Dietrich, executivo da IBM de Watson™ (AI & Data), elucidou a metodologia típica para abordar projetos de IA em uma Web série disponível no Youtube desde 2018, denominada "O Ciclo de AI". Segundo Dietrich (2018), existe uma sequência de etapas a serem seguidas na elaboração deste tipo de projetos, o que facilita sua concepção.

3.1.1 Fase 1 do Ciclo de AI: Design e Planejamento

Esta etapa tem início com a identificação do problema ou oportunidade de negócio na qual o sistema com inteligência artificial será aplicado. Em seguida, deve-se pensar em quem será atingido com este sistema, ou seja, a persona⁷. Também é recomendado que sejam considerados indicadores de performance para medir o sucesso do negócio, utilizando inteligência artificial.

Continuando, deve-se questionar quais dados serão necessários e qual o formato dos dados disponíveis, ou seja, se são digitalizados ou analógicos, estruturados ou não, qual a privacidade dos dados, entre outras informações.

Após a identificação dos dados a serem utilizados, é possível criar um caso de uso de IA, onde seja viável colocar a inteligência artificial em prática. O caso é baseado tanto na oportunidade quanto nos dados disponíveis, permitindo a geração e mensuração de valor.

3.1.2 Fase 2 do Ciclo de AI: Dados

A partir dos dados identificados como necessários na Fase 1, dá-se início à coleta dos mesmos na Fase 2. Os dados podem estar armazenados em bases de dados, ou estarem disponíveis em bases públicas. Às vezes, se faz necessária a geração de dados, caso ainda não existam. Neste modelo, a geração é chamada de aquisição. Com os dados em mãos, deve-se prepará-los para a fase seguinte. Paralelamente ao preparo, existe a etapa de anotação dos dados, ou seja, a intervenção humana para rotular os dados disponíveis, o que será muito útil no posterior treinamento do algoritmo.

⁷ Persona é um termo utilizado no marketing que consiste em uma representação fictícia do cliente ideal de um negócio. A descrição de uma persona contempla suas principais características, hábitos e interesses, incluindo gênero e faixa de renda, estipulados por informações de clientes atuais e potenciais.

3.1.3 Fase 3 do Ciclo de AI: Treinamento

Com os dados preparados, deve-se avaliar quais deles realmente serão utilizados, separá-los em dados para teste e dados para treinamento e definir o algoritmo mais adequado a ser aplicado. Isto constitui a etapa de análise dos dados. Após estas definições, realiza-se a construção e treinamento do modelo selecionado, seja de *Machine Learning*, *Deep Learning* ou outro algoritmo. Em seguida, deve-se verificar o comportamento do modelo, se está de acordo com o que se esperava. Para isso, algumas métricas podem ser analisadas, como a precisão e acurácia das respostas fornecidas pelo modelo. No início, o modelo costuma apresentar uma acurácia mais baixa, o que impulsiona sua reavaliação, para refiná-lo ou buscar mais dados. A fase de treinamento consiste em um processo iterativo, até que se alcance a acurácia desejada para o caso de uso selecionado, em geral, determinada por uma porcentagem de acertos nas respostas fornecidas. Mesmo que o valor ainda não seja tão elevado quanto se gostaria, seguir para a próxima fase (de produção) pode ser uma boa opção, pois permite a coleta de novos dados e informações, que poderão servir para refinar o treinamento do modelo.

3.1.4 Fase 4 do Ciclo de AI: Inferência

A primeira etapa desta fase é a implantação do modelo, ou seja, levar o modelo construído e treinado na Fase 3 para um ambiente de produção, como inseri-lo em um aplicativo já existente, ou disponibilizá-lo como uma API (*application programming interface*, em português: interface de programação de aplicativos) ou um micro serviço que possa ser acessado sempre que necessário. Quando o modelo é levado para um ambiente de produção, ele passa a receber os dados de entrada, aqueles inseridos por usuários. Os usuários costumam ser representados pela persona definida na Fase 1. Com estes dados, o modelo passa a ser utilizado de fato, gerando resultados. Os resultados podem ser fornecidos diretamente para os usuários ou podem estar inseridos em uma sequência de ações para uma aplicação mais ampla. A interação dos humanos com os resultados finais que recebem configura um *feedback*, muitas vezes coletados por um clique em um sinal

de positivo ou negativo. Este *feedback* possui alto valor e deve ser armazenado, assim como os resultados fornecidos, pois evidenciam a evolução do modelo. A fase de inferência também possui um aspecto iterativo, interligando-se com a Fase 3, de treinamento, pois os *feedbacks* retroalimentam o modelo, permitindo uma nova análise dos dados e treinamento, o que pode resultar em um aumento na acurácia e precisão.

3.1.5 Fase 5 do Ciclo de AI: Evolução

A quinta fase, mais que um passo a passo, serve como uma liga para todo o modelo. Engloba todas as fases, envolvendo-as em um ciclo contínuo, até que se alcancem os resultados desejados para a aplicação. Assim, o feedback coletado na Fase 4 é utilizado como massa de dados para a retroalimentação do modelo, sendo enviada novamente para a análise de dados, etapa da Fase 3. A precisão desejada do modelo deve estar de acordo com o caso de uso e as métricas de performance selecionados na Fase 1. Pode-se chegar à conclusão que novos dados são necessários para que se melhore a performance para aquele caso de uso, onde a Fase 2 é revisitada. Portanto, a Fase 5, de evolução, percorre todas as fases já descritas, pois permite a atualização do modelo de acordo com elementos presentes nas demais fases.

Dessa forma, as cinco fases compõem um modelo cíclico, chamado de Ciclo de AI. O esquema abaixo retrata todas as fases e suas respectivas etapas.

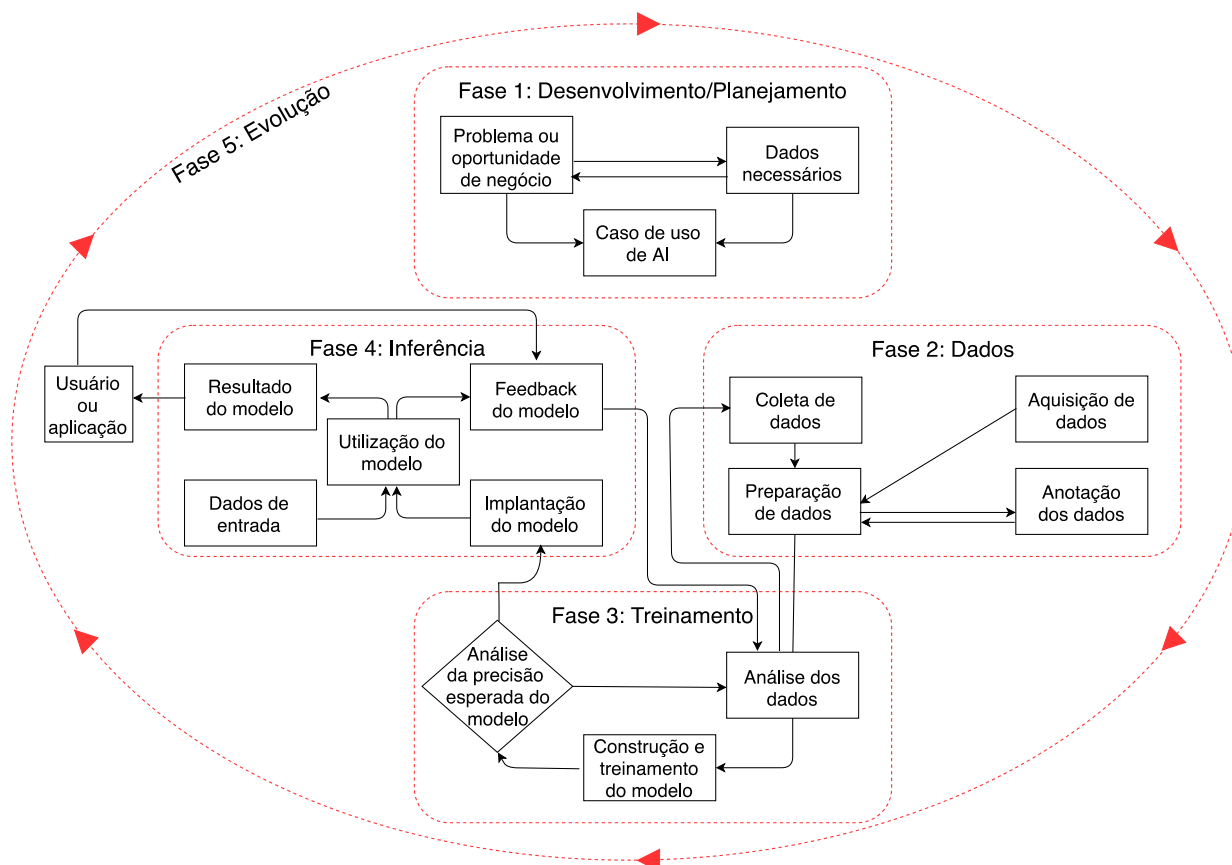


Figura 12 – Esquema representativo do Ciclo de AI

Fonte: Adaptado do esquema apresentado na Websérie “O Ciclo de AI” (DIETRICH, 2018).

3.2 IBM WATSON® VISUAL RECOGNITION E IBM WATSON® STUDIO

Os serviços de Watson™ Visual Recognition empregam algoritmos de *deep learning* para analisar imagens de cenas, objetos, rostos e outros conteúdos. Já existem alguns modelos pré-construídos que podem ser utilizados. Nestes casos, não há necessidade de treinamento por parte do usuário da aplicação. Exemplos de modelos já construídos são o modelo geral (*default*), que contém uma grande diversidade de imagens, o modelo de reconhecimento facial, que sugere faixa de idade e gênero baseado em um rosto e até mesmo um modelo especializado em comidas, dentre outros modelos. As respostas fornecidas por estes classificadores incluem palavras-chave, exibidas em lista, que oferecem informações sobre o conteúdo da imagem. A lista contém todos os objetos identificados na imagem, bem como a confiabilidade calculada para cada objeto. O serviço de Visual Recognition

está dentro da IBM Cloud™, (ou Bluemix®), onde os outros serviços de Watson™ também estão hospedados, facilitando sua futura integração.

O Watson™ Studio, outro componente da plataforma de serviços de IA da IBM, permite que sejam treinados modelos customizados, onde novas classes podem ser criadas a partir de conjuntos de imagens. O único requisito é que sejam inseridos pelo menos dois *sets* de imagens (referentes a duas classes), com o máximo de dados/imagens possíveis. Estes *sets* podem incluir duas classes “positivas” ou uma classe positiva e outra “negativa”. A fim de exemplificar, tomemos um modelo que diferencia duas raças de cães, como *Border Collie* e *Golden Retriever*. Uma classe positiva seria um grupo de imagens de cães apenas de determinada raça (ou seja, um *set* para os *Border Collies* e outro para os *Golden Retrievers*). Já a classe negativa seriam imagens de gatos, coelhos, outros animais e até mesmo outras raças, como Dálmatas. A classe negativa contém exemplos que não devem ser detectados pelo modelo. As imagens relativas às classes devem ser zipadas em pastas diferentes e depois submetidas no Watson™ Studio, onde é feita a gestão das imagens e onde o treinamento irá ocorrer. Dessa forma, o Watson™ Studio engloba o kit de ferramentas para realizar o treinamento do modelo customizado a ser desenvolvido, sendo os artifícios de treinamento armazenados na Cloud. O fluxograma abaixo explicita a integração entre os serviços Visual Recognition, Watson™ Studio e o armazenamento na IBM Cloud™.

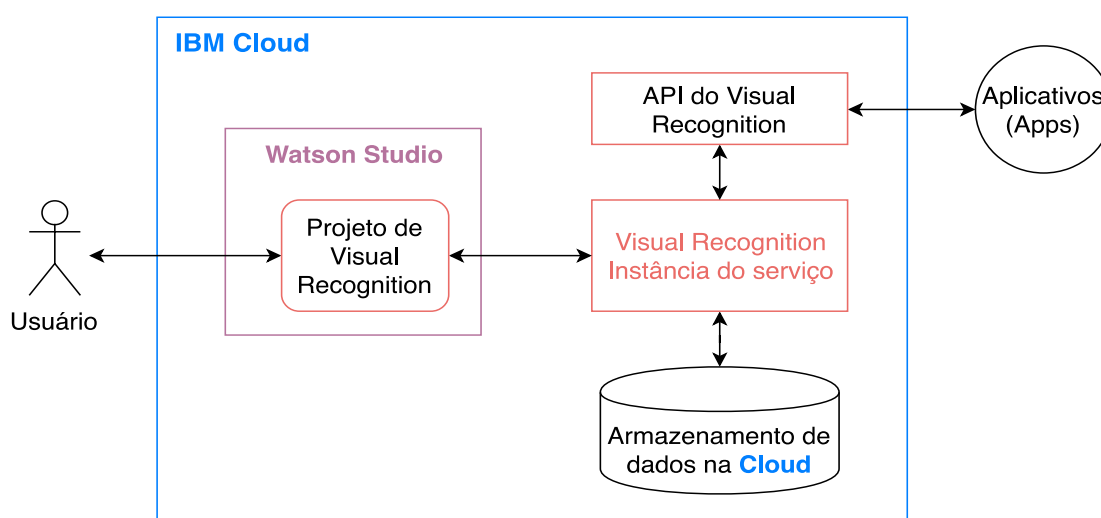


Figura 13 – Arquitetura de integração entre os serviços IBM e os usuários

Fonte: Adaptado de modelo apresentado em treinamento⁸ sobre Watson™ Visual Recognition, IBM

⁸ Treinamento disponível em <<https://www.onlinedigitallearning.com/course/view.php?id=4308>>

Para o trabalho em questão, os dois serviços serão utilizados, pois pretende-se criar um novo modelo para reconhecimento de microconstituintes de aços em imagens metalográficas. Assim, foi criada, primeiramente, uma instância específica do Visual Recognition, onde o modelo customizado será desenvolvido. Para isso, deve-se acessar a Cloud da IBM (encontrada em: <<https://console.bluemix.net/>>) e clicar na aba *Catalog* (catálogo). Nesta aba, todos os serviços oferecidos na Cloud pela IBM são exibidos. Deve-se procurar o serviço Visual Recognition e selecioná-lo.

Uma tela será exibida, onde é possível definir o nome da instância, bem como o plano de cobrança desejado, que varia de acordo com as funcionalidades desejadas (quantidade de chamadas de API, quantidade de modelos disponíveis). A versão grátis já garante todas as funcionalidades desejadas até o presente momento, permitindo 1000 chamadas de API por mês e 2 modelos customizados disponíveis. Além disso, exibe-se a região onde a aplicação será hospedada. Deve-se clicar em "Create", para criar o modelo. A instância foi nomeada como "Visual Recognition-fases de aços". A seguir, a tela abaixo será exibida, mostrando parâmetros de API (para realizar integrações com outros aplicativos) e outras informações sobre a instância.

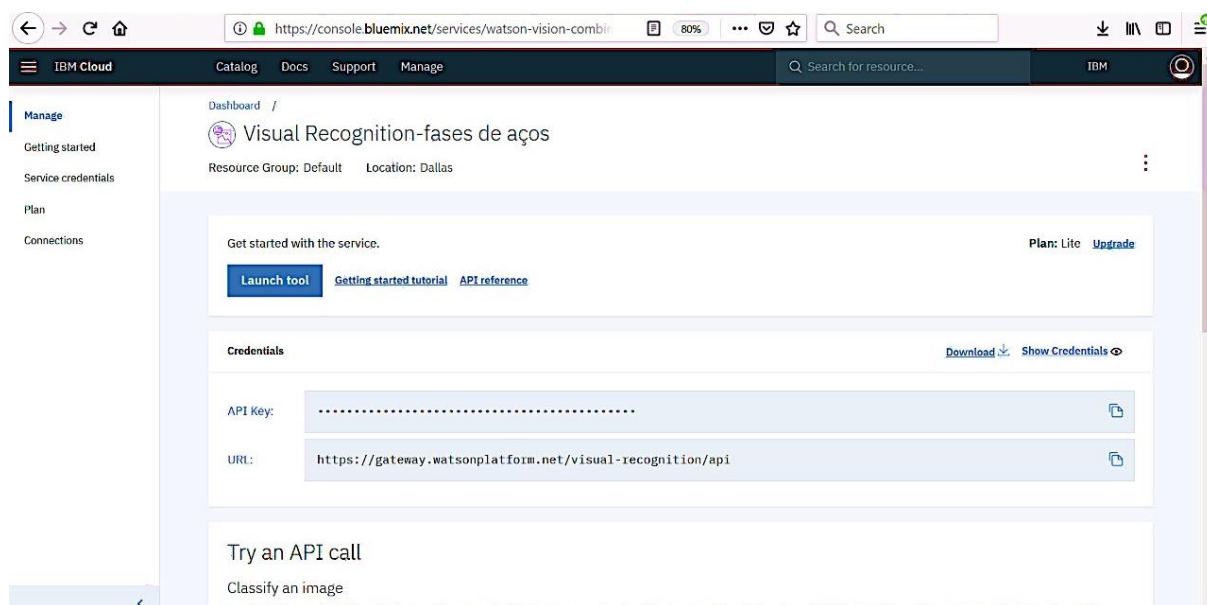


Figura 14 – Tela com parâmetros de API e informações gerais da instância de Watson™ Visual Recognition criada

Fonte: Elaboração própria, 2019.

O mesmo passo a passo foi seguido para criar uma instância de Watson™ Studio. A instância foi nomeada como "Watson Studio-fases de aço". A região de hospedagem e o grupo devem ser os mesmos que os selecionados para a instância do Visual Recognition.



Figura 15 – Região e grupo de hospedagem das instâncias

Fonte: Elaboração própria, 2019.

Será exibida uma tela sobre a instância recém criada, semelhante a Fig. 12. Deve-se clicar em “*Get Started*”, que irá direcionar para a ferramenta do Watson™ Studio. Na ferramenta, deve-se clicar em “*New Project*” e selecionar o tipo de projeto, que será “*Visual Recognition*”. Em seguida, são definidos o nome do projeto e sua descrição. Novamente, o botão “*Create*” é clicado. Por fim, chega-se na tela abaixo, com as instruções e ferramentas para criar o modelo, que foi nomeado, inicialmente, como “*Reconhecimento de fases*”. Posteriormente, o modelo foi renomeado para “*Reconhecimento de microconstituintes de aço 2*”.

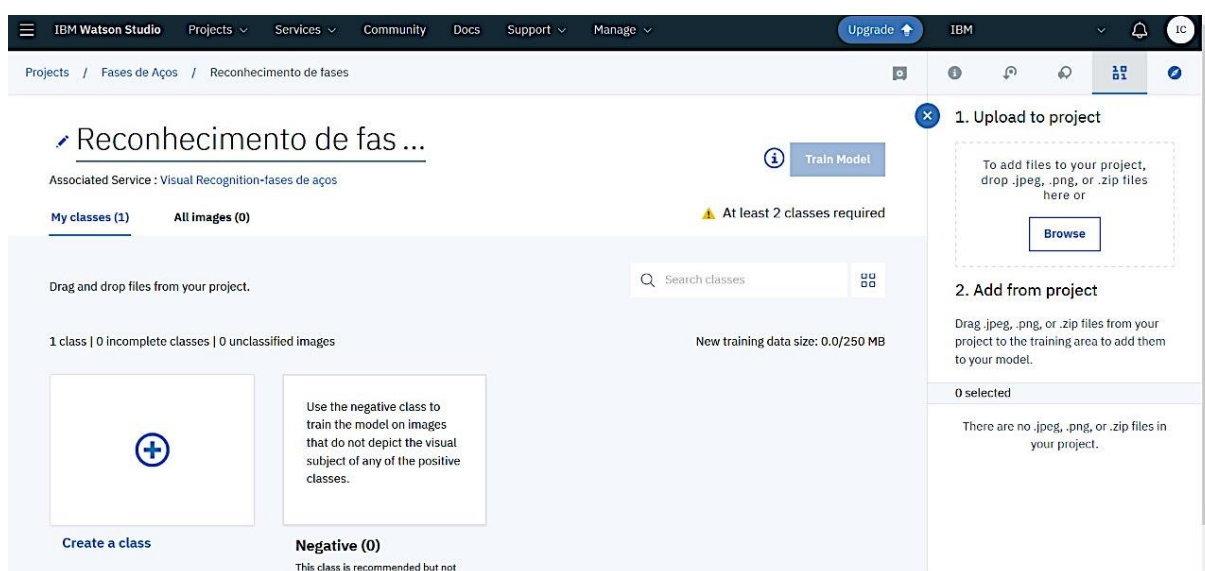


Figura 16 – Tela de edição do modelo no Watson™ Studio

Fonte: Elaboração própria, 2019.

3.3 MÉTODO ADOTADO / PLANO DE TRABALHO

Conforme o método sugerido para projetos de Inteligência Artificial, na Web série “**O Ciclo de AI**” (DIETRICH, 2018), descrita na seção 3.1 deste estudo, foi elaborado um plano de trabalho para atacar a questão do reconhecimento das microestruturas presentes em aços. As etapas do plano de trabalho serão descritas com maiores detalhes nas próximas seções e estão baseadas na metodologia do “Ciclo de AI”, com algumas adaptações.

3.3.1 Design e Planejamento

Conforme descrito na introdução deste trabalho, a Engenharia Metalúrgica e de Materiais tem muito a se beneficiar da utilização de ferramentas de automação. Isto inclui aplicações com Inteligência Artificial, que permitam maior velocidade nas análises industriais, realizadas por especialistas. Dessa forma, pode-se afirmar que existe uma oportunidade de negócios a ser explorada neste campo. Contudo, é preciso afunilar o problema e selecionar um tipo de análise a ser automatizada através do uso de IA. Então, selecionou-se a análise microestrutural de aços como oportunidade de negócios a ser trabalhada. A aplicação a ser desenvolvida realizará o reconhecimento de imagens de microestruturas obtidas com microscópios ópticos.

Em seguida, determinaram-se os dados necessários para construir a aplicação. Como a aplicação trabalhará com imagens de microestruturas, é necessário montar um banco de dados que permita que a diferenciação das diversas fases e microconstituintes possíveis em aços.

Com a oportunidade identificada e os dados determinados, pode-se estruturar o caso de uso para aplicação do modelo pretendido. Neste trabalho, por não se saber ao certo qual precisão será alcançada, optou-se por desenvolver um caso de uso com estudantes universitários, principalmente dos cursos de Engenharia Metalúrgica e de Materiais ou de Ciência dos Materiais, para auxiliar os mesmos em matérias do curso. Os estudantes também podem fornecer uma massa de dados a ser utilizada para refinamento do modelo. Assim, a persona deste caso de uso pode ser definida como um estudante universitário, na faixa dos 20 anos de idade, preocupado com seu desempenho na faculdade, porém um entusiasta tecnológico.

Já quanto as métricas de sucesso deste caso de uso, pode-se assumir, inicialmente, que 60% de precisão seria adequado aos alunos, pois os mesmos podem buscar orientação em casos de dúvida. Além disso, 60% é superior ao maior valor possível de aleatoriedade, pois, supondo apenas duas classes, este valor seria de 50%. O aumento do número de classes diminui a chance randômica de acerto.

3.3.2 Dados

Os dados necessários foram descritos na sessão acima e precisam ser coletados. Existem muitas imagens disponíveis em sites de busca, como o Google, mas também existem livros com uma rica biblioteca de imagens, como é o caso do livro de Colpaert (2008), uma das referências mais importantes para este trabalho. Existem também atlas metalográficos e uma vasta diversidade de artigos sobre microestruturas disponíveis em sites acadêmicos. Ainda, encontram-se fotos no acervo pessoal de Professores e pesquisadores que trabalham na área. Também foram utilizadas micrografias encontradas no laboratório de metalografia do Departamento de Engenharia Metalúrgica e de Materiais da USP (PMT-USP) e observadas em aula. Outras referências para esta etapa foram: livros como *Steels: Processing, structure and performance* (KRAUSS, 2015), *ASM Metals Handbook v. 9 - Metallography and Microstructures* (ASM INTERNATIONAL, 2004) e *Aços e ligas especiais* (SILVA; MEI, 2006); bibliotecas de imagens virtuais como *Dissemination of IT for the Promotion of Materials Science (DoITPoMS)* (UNIVERSITY OF CAMBRIDGE, 2018), *Materiales y Ensaíos: Microconstituyentes de los Aceros* (RODRÍGUEZ, 2011), *Metallography General* (VANDER VOORT, 1967-2009), *Proyecto de Innovación Atlas Metalográfico* (DURÁN, 2016) e *Microstructure and corrosion of steels database* (DEGRIGNY, 2016); artigos disponíveis na internet, como Li (2017), Coelho (2008), Vander Voort (2015) e outros artigos contidos no site da companhia VAC AERO International Inc. (VAC AERO INTERNATIONAL INC., 2016).

Com as imagens em mão, as mesmas devem ser anotadas, ou seja, separadas em suas devidas classes, de acordo com as fases e/ou microconstituintes presentes. Esta classificação ocorre manualmente, portanto, é importante que as imagens destinadas ao treinamento confirmem o maior grau de confiabilidade possível

para a aplicação. Isto é, não devem ser incluídas no treinamento imagens cuja classificação manual seja difícil ou incerta – por isso, inicialmente, casos como bainita e ferrita W não serão considerados escopo deste modelo, pois possuem características mais complexas. Devem ser buscadas figuras representativas, com boa resolução e distinção clara dos componentes presentes, pois a qualidade das imagens utilizadas no treinamento definem como será a performance do classificador (DECOST; FRANCIS; HOLM, 2017).

Em um primeiro momento, pensava-se que seria melhor inserir no modelo micrografias com figuras das fases e/ou microconstituintes “puros”, ou seja, isolados. Contudo, as micrografias com uma fase apenas não seriam representativas para o reconhecimento das fases em micrografias mais complexas. Por exemplo, a ferrita pura/isolada não apresenta semelhança visual suficiente com a ferrita presente em uma microestrutura composta por ferrita e perlita (com maior teor de perlita), conforme imagem abaixo:




Figura 17 – Comparação entre a morfologia da ferrita: (a) pura (b) em uma microestrutura com presença majoritária de perlita (componente escuro).

Fonte: (a) Extraída de ASM Metals Handbook v. 9 - Metallography and Microstructures (ASM INTERNATIONAL, 2004); (b) Adaptada de imagem obtida de Dissemination of IT for the Promotion of Materials Science (DoITPoMS) (UNIVERSITY OF CAMBRIDGE, 2018)

Dessa forma, optou-se por separar as classes de acordo com os conjuntos de microestrutura mais comuns, como ferrita e perlita, austenita e martensita, etc., além de fases puras, como a ferrita.

A classificação ocorreu paralelamente a coleta das imagens, pela organização das mesmas em pastas de arquivo no computador, de acordo com a microestrutura exibida em cada foto. Esta etapa foi bastante complexa, pois são as pastas que definem as classes que serão adicionadas ao modelo. Ainda, foram analisadas as quantidades de imagens em cada pasta, para definir as classes que seriam inseridas primeiro, ou seja, as que dispunham de um maior número de fotos de boa qualidade. Além disso, foi possível determinar qual microestrutura precisava de mais fotos, realizando pesquisas direcionadas para encontrar mais imagens que poderiam ser úteis.

Uma maneira de aumentar a quantidade de imagens em um banco de dados é a manipulação das imagens, aplicando rotação, mudando a escala ou cortando partes das imagens (IBM CLOUD, 2019). Isto foi utilizado neste trabalho, principalmente o corte das imagens, pois muitas continham barra de escala sobrepostas à microestrutura, sendo esta barra removida manualmente com o corte das imagens. A presença da barra de escala interfere na etapa de extração de características (*feature extraction*) dos algoritmos de *machine/deep learning*, o que reforça que as mesmas devem ser retiradas das figuras do banco de treinamento do modelo, através de cortes nas imagens originais. Isto também ajuda na obtenção de mais imagens para o banco, além da possibilidade de adequar as dimensões para uma proporção padrão (CHOWDHURRY *et al.*, 2016; DECOST; FRANCIS; HOLM, 2017). A figura abaixo ilustra esta operação:




Figura 18 – Simulação de cortes realizados em uma imagem do banco de dados para remoção da grade de escala

Fonte: Elaboração própria, 2019. Imagem original obtida de Microstructure and corrosion of steels database (DEGRIGNY, 2016).

Existem algumas variáveis importantes quando se aborda o aspecto de microscopias, como a escala (ou aumento microscópico utilizado), quantidade de luz (que define a profundidade dos detalhes revelados), resolução (associado com o foco das imagens) e cor (em decorrência do ataque químico utilizado). Todos estes fatores corroboram para tornar a microscopia um campo muito amplo. Para este trabalho, dado o teor amplo do mesmo (função acadêmica), foi necessário limitar as variáveis de imagem para realizar a construção do modelo. Para a escala, por exemplo, definiu-se que deveria ser, pelo menos, equivalente a um aumento de 200x no microscópio óptico, caso contrário, a classificação microestrutural pode ser prejudicada, mesmo para um profissional altamente capacitado, pois poucos materiais possuem microconstituintes que apresentem boa resolução em aumentos tão pequenos. A definição da resolução ótima para as imagens de treinamento depende do caso de uso, pois não adianta treinar um modelo com imagens de altíssima qualidade, se os usuários da aplicação irão enviar imagens de menor qualidade, obtidas em aula e não em um microscópio robusto. Deve-se sempre

lembrar desta boa prática, de manter as imagens de treinamento o mais semelhante possível com as que os usuários irão enviar. Portanto, uma imagem levemente trêmula é tolerável.

O ataque químico das amostras pode conferir resultados visualmente muito diferentes, sendo recomendável selecionar um tipo de ataque para padronizar a classificação. Caso contrário, pode ser necessário criar classificadores separados para os diferentes ataques em questão. Assim, foram priorizadas as imagens onde as amostras foram atacadas com Nital (algumas imagens de carbonetos possuíam ataque de picral; outras, não informaram o ataque, apesar da semelhança com as imagens produzidas com Nital). O Nital é o reagente para ataque mais utilizado atualmente na análise de microestruturas de aços, revelando os contornos de grãos ferríticos e a morfologia da martensita (VANDER VOORT; MANILOVA, 2005; VANDER VOORT, 2011).

Com a maioria das imagens em mão, foi possível prosseguir para a etapa de treinamento, onde as primeiras classes serão adicionadas ao modelo.

3.3.3 Treinamento

Com os dados reunidos (imagens agrupadas em pastas de acordo com a fase/microconstituente presente), deve-se realizar uma separação das imagens destinadas para treinamento do modelo e das imagens de teste, ou seja, as que servirão para analisar a performance do modelo antes da fase de inferência. Os dados de teste devem ser inéditos ao modelo, pois não foram utilizados na etapa de desenvolvimento com os algoritmos. As imagens de teste e treinamento devem ser separadas aleatoriamente, dentro de cada classe, para formar uma massa adequada, sem viés.

A quantidade de imagens do banco destinadas ao treinamento e ao teste varia, porém, tipicamente, assume-se a proporção 80-20 (80% das imagens para o treinamento do modelo e 20% para os testes). Essa será a proporção adotada nos testes a serem realizados, exceto hajam evidências de que uma nova proporção possa trazer melhores resultados para o caso estudado. As imagens do grupo treinamento e do grupo testes devem ser parecidas entre si (e com as imagens que se espera receber dos usuários finais), pois a presença de características visuais

muito distintas poderá resultar em resultados de baixa performance. Boas práticas sugerem que sejam utilizadas no mínimo 50 imagens para treinar uma classe, sendo o número ideal entre 150 e 200. A partir de 5000 imagens, não há registro claro de melhoria na classificação. Para este estudo, foi definida uma massa crítica de aproximadamente 100 imagens por classe, sendo aproximadamente 80 para treinamento do modelo e 20 para testes. As imagens separadas para testes serão utilizadas sempre que uma nova classe for inserida, pois servem para validar não só a classe que representam, mas também as demais.

Imagina-se que esta etapa, em conjunto com a de coleta dos dados, serão as mais longas do processo. Quando a acurácia desejada for atingida, o modelo poderá ser levado para um ambiente de produção e exposto às personas definidas na seção 3.3.1.

3.3.3.1 Metodologia para sorteio das imagens

Conforme explicado na seção anterior, a seleção entre imagens de treinamento e de teste do modelo deve ser aleatória. Dessa forma, foi elaborada uma metodologia simples de sorteio, utilizando o programa Excel.

Para cada classe, os nomes das imagens foram inseridos em uma planilha do Excel, todas em uma mesma coluna, de acordo com a ordem em que estavam dispostas na pasta do computador (alfabética). Em seguida, os números relativos a ordem inicial foram adicionados na coluna à direita. Por fim, na terceira coluna da tabela, foi utilizado o operador =RAND() do Excel. Este operador determina um número aleatório (entre 0 e 1) para cada célula em que a fórmula for inserida. Com o preenchimento da coluna, é necessário copiar os valores sorteados e colar novamente no Excel, porém selecionando a opção de “colar especial” e escolhendo “valores”. Isto é necessário pois cada nova interação com a planilha resulta em um novo sorteio da função RAND. Com os valores sorteados, é possível ordenar a tabela, exibindo os valores aleatórios em ordem crescente. Os primeiros 80% das imagens serão destinados ao treinamento e os últimos 20% aos testes.

3.3.3.2 Prova de compatibilidade e utilização do Watson™ Visual Recognition

Antes de iniciar o desenvolvimento do modelo final, é necessário testar se os algoritmos do Watson™ Visual Recognition são adequados ao caso de uso selecionado, ou seja, o reconhecimento de componentes microestruturais de aços. Um primeiro teste foi conduzido com um conjunto de imagens referente a uma microestrutura composta por ferrita e perlita. Foram coletadas inicialmente 74 imagens nas fontes descritas na seção 3.3.2, buscando aumentos, quando possível, de pelo menos 100x. A escala, em um primeiro momento, não será considerada como limitante, sendo inseridas imagens com aumentos variados, porém resultados mais precisos podem ser obtidos com uma padronização do aumento e, conseqüentemente, das imagens.

O sorteio das imagens foi realizada conforme descrito em 3.3.3.1, sendo 59 imagens para treinamento (80% do total) e 15 (20%) para testes. Como as imagens não são completamente homogêneas, devido a fatores como o aumento empregado, a quantidade de perlita e ferrita, entre outros fatores de qualidade de imagens, deve-se analisar, após o sorteio, se não foram formados agrupamentos de fotos muito parecidas, de forma a isolá-las em um dos grupos (treinamento/teste).

Após a seleção das imagens para treinamento, é recomendado salvá-las em uma pasta compactada (ex. .zip) para facilitar a inserção e manuseio no classificador. As pastas compactadas podem ser adicionadas no canto superior direito da tela, no item 1., conforme exibido na Figura 15. Para criar uma classe, basta clicar no sinal de “+”, também exibido na Fig. 15. A tela abaixo retrata o aspecto do modelo após criação de uma classe, neste caso, Ferrita&Perlita. Deve-se atentar às restrições de caracteres dos nomes das classes, sendo “espaço” um dos caracteres não aceitos.



Figura 19 – Classes criadas para a prova de fogo. Apenas imagens de treinamento deverão ser adicionadas às classes.

Fonte: Elaboração própria, 2019.

Para que o modelo possa ser criado e testado, são necessárias ao menos duas classes, podendo ser uma delas a classe negativa. Como a única classe de microestrutura utilizada na prova de compatibilidade foi a Ferrita&Perlita, foi necessário adicionar outras fotos de microestruturas que não continham ferrita ou perlita na classe negativa. Foram selecionadas algumas imagens (mistas ou não) de martensitas, bainitas, carbonetos e cementita, entre outras. No total, 35 imagens foram utilizadas, sendo 28 para treinamentos e 7 para testes, sorteadas de acordo com a metodologia de sorteio no Excel.

Após a adição das pastas compactadas as suas respectivas classes, é possível iniciar o treinamento do modelo, clicando no botão azul “Train Model”, conforme exibido na figura abaixo. O treinamento levou cerca de 30 minutos para ser concluído.



Figura 20 – Tela do Watson™ Visual Recognition mostrando que o modelo está pronto para ser treinado

Fonte: Elaboração própria, 2019.

3.3.3.3 Teste e avaliação dos resultados do modelo

Os testes do modelo serão realizados na própria interface disponibilizada no Watson™ Visual Recognition, onde é possível observar o índice de confiabilidade calculado para cada imagem inserida. Os resultados desta prova de compatibilidade estão detalhados no capítulo Resultados, e foram satisfatórios para que se desse continuidade na construção do modelo, cujos resultados também serão apresentados posteriormente.

A avaliação dos resultados terá como base dois parâmetros: acurácia e índice de confiabilidade (IC). A acurácia baseia-se na quantidade de acertos do modelo, ou seja, sua assertividade em classificar a imagem na classe correta ou predominante. A acurácia será medida através da divisão do número de imagens classificadas corretamente pelo número total de imagens testadas. Dessa forma, quanto mais próximo de 1 for este valor, maior acurácia o modelo possui. O IC é um parâmetro nativo do Watson™ Visual Recognition, baseado na classificação estatística realizada pelo modelo. É um valor comparável, que pode variar entre 0 e 1, mas não deve ser lido como uma porcentagem. Quanto maior a pontuação para uma classe, maior é a certeza do modelo de que a mesma encontra-se presente na imagem

analisada. O valor do IC pode ser utilizado para estimular alguma ação de um aplicativo sendo desenvolvido, sendo este valor chamado de “limite de decisão” (*threshold*). Este valor não é calculado pelo serviço, mas o *threshold* padrão sugerido é de 0,5.

Os resultados foram compilados em tabelas no Excel, registrando a acurácia e IC para as classes avaliadas.

3.3.3.4 Construção da primeira versão do modelo de classificação de microestruturas de aços

Após a Prova de compatibilidade, um segundo modelo foi criado, pois mais fotos de ferrita e perlita foram obtidas, com qualidade superior às que haviam sido utilizadas no primeiro teste. Além disso, algumas imagens continham microconstituintes como bainita e tiveram de ser excluídas da classe, para não gerar resultados errôneos. Ainda, algumas delas apresentavam resolução muito baixa ou escala inadequada (pouco aumento), o que dificulta a classificação de qualquer microestrutura. Infelizmente, para remover imagens ou classes de um modelo já treinado no Watson™ Visual Recognition, é necessário que seja criado um novo modelo. A conta gratuita garante o acesso a dois modelos de classificadores, sendo possível treinar um novo modelo sem perder o anterior definitivamente. Assim, das 59 imagens de treinamento da Prova de compatibilidade, 48 foram selecionadas para criar o novo modelo. Dessa forma, o primeiro *set* de treinamento foi mantido, com as 48 imagens “repetidas”, assim como o *set* de teste, que se manteve idêntico ao primeiro, com 15 imagens. Nesta situação, têm-se a proporção treinamento-teste de 76 - 24%. Para a segunda etapa, foram coletadas novas 123 imagens de ferrita e perlita, resultando em 186 imagens no total. Para manter a proporção ideal de 80-20%, a classe precisará de um total de 149 imagens de treinamento, portanto, deve-se selecionar 101 imagens dentre as novas. Utilizou-se o mesmo método de sorteio via Excel já descrito anteriormente.

O modelo requer duas classes para que possa ser utilizado, mas não é obrigatório que se utilize a classe negativa. Portanto, pode-se selecionar outra fase ou microconstituente para ser inserido em uma nova classe.

A próxima microestrutura estudada para ser inserida no modelo foi a martensita. Como a martensita pode se manifestar em diversas formas, como martensita em ripas (de baixo carbono) e em placas (de alto carbono), pode ser necessário criar mais de uma classe para conseguir um classificador eficaz. Contudo, o treinamento do modelo ocorre através de submodelos separados para cada classe, utilizando todas as outras como exemplos negativos da classe sendo treinada. Logo, deve-se tomar o cuidado de não criar classes que possuam intersecções, garantindo que todas os exemplos positivos de uma classe estejam presentes na mesma, para que não sejam utilizados como exemplos negativos no treinamento dos submodelos, pois isto pode prejudicar o treinamento e os resultados gerais do classificador.

As imagens de martensita então foram separadas em dois grupos: 1- martensita e austenita retida (morfologia predominantemente de martensita em placas); 2- martensita em ripas, mista e revenida. Neste momento, optou-se por inserir o primeiro grupo no modelo, em uma classe chamada de Martensita. O grupo 1- foi selecionado pois continha imagens com menor margem de dúvida quanto os constituintes presentes, predominando a martensita (em placas) e austenita retida, microestrutura que possui características mais marcantes. Além disso, o grupo 1- compreendia um número de imagens maior e as mesmas eram mais representativas. Num segundo momento, as demais imagens de martensita (grupo 2-) poderão ser inseridas no modelo, seja em uma nova classe ou na de Martensita já existente.

Isto posto, a classe Martensita foi configurada a partir de 91 imagens, inicialmente. O sorteio treinamento 80 - teste 20 foi realizado novamente no Excel, totalizando 73 imagens para treinamento e 18 para teste. Posteriormente aos testes, mais 4 imagens de martensitas foram adicionadas à classe Martensita.

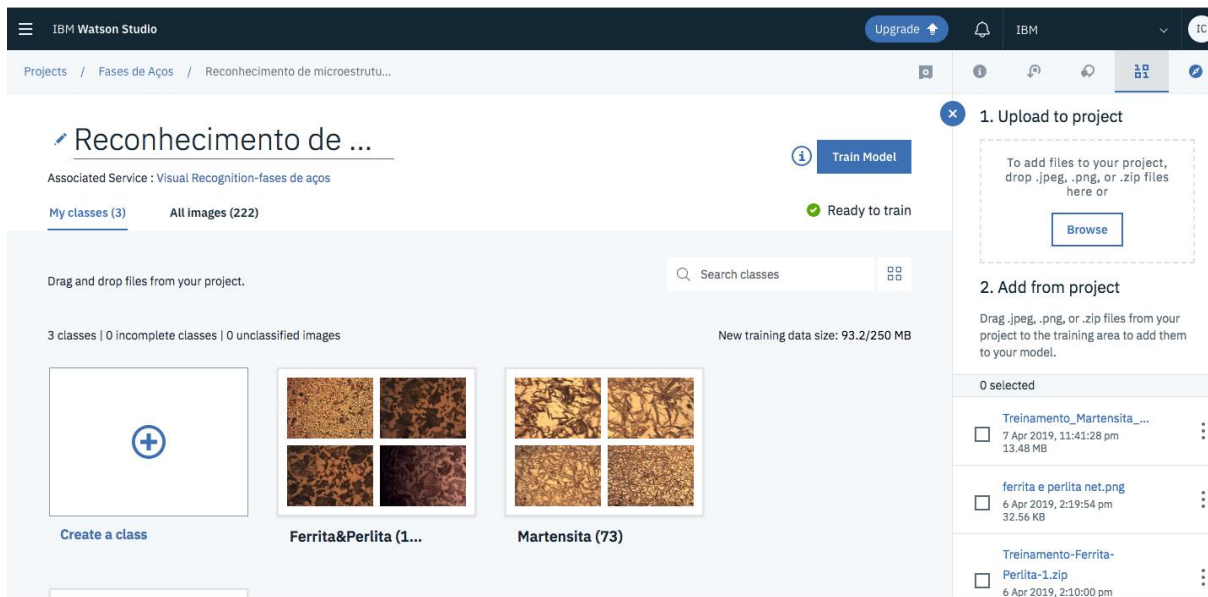


Figura 21 – Tela do Watson™ Visual Recognition mostrando as novas classes criadas

Fonte: Elaboração própria, 2019.

O modelo se auto treinou por cerca de 30 minutos com as duas novas classes inseridas. Após o treinamento completo do modelo, foi possível realizar testes para verificar a acurácia e confiabilidade (IC) do modelo até o momento, apresentadas na seção 4.2.1.

A próxima classe criada foi a de Carbonetos. Nesta classe, representada principalmente por fotos de aços ferramenta, foi necessário um cuidado extra: a distinção da matriz (ferrítica, martensítica, entre outras) pode prejudicar a performance do classificador. Como as classes do modelo são utilizadas como exemplos negativos para o treinamento das demais classes, uma imagem de carbonetos que apresente distinção clara da morfologia da matriz poderá ser utilizada como exemplo negativo para a classe representante da matriz, como a classe Martensita.

No momento de criação da classe Carbonetos, 120 imagens haviam sido selecionadas. Seguindo a proporção de 80-20 (treinamento-teste), foram sorteadas pelo Excel 96 imagens para treinamento e 24 para testes. O treinamento durou aproximadamente 1h e os resultados obtidos podem ser verificados na seção 4.2.1.

Em seguida, a classe ferrita foi inserida no modelo. Foram utilizadas 100 imagens no total, 80 para treinamento e 20 para testes, sendo o sorteio realizado da mesma forma que nas demais classes.

Como a classe Martensita foi a única que não atingiu a massa crítica de 100 imagens por classe, foram buscadas novas imagens para inserção no modelo. Foram obtidas novas 21 imagens de martensita em placas, sendo 17 destinadas ao treinamento e 4 aos testes. A classe Martensita agora possui 94 imagens de treinamento e 22 de teste. Esta versão do modelo contou com 402 imagens de treinamento e 99 de testes, no geral.

Com uma prévia do modelo final preparado, deve-se avaliar os resultados dos testes e determinar se o classificador pode ser levado para um ambiente de implementação, seguindo para a fase 4 do Ciclo de AI (inferência). Após a conclusão da fase 4, é possível retornar para esta fase (3 – treinamento), pois classes poderão ser criadas ou refinadas.

3.3.4 Inferência

Esta etapa visou o desenvolvimento de uma interface amigável para o usuário, cuja interação com o modelo será feita a partir de uma página na web com instruções de uso. Esta interface será realizada também com produtos da IBM Cloud™. Como os resultados do modelo foram superiores a acurácia desejada inicialmente, o modelo foi levado para o ambiente de produção.

Para implementar o modelo em uma aplicação, é necessário que se tenha algum conhecimento básico na área de programação, apesar de a infinidade de material autodidata disponível na internet. A fim de lançar uma primeira versão da aplicação, foi utilizado um código pré-programado para uma demonstração⁹ realizada por desenvolvedores da IBM, disponível na plataforma GitHub¹⁰, de acesso aberto. Esta página web permite que seja selecionado qual modelo será utilizado para classificar a imagem, dentre os disponíveis na conta IBM associada. No código inicial, a imagem deveria ser inserida como uma URL. Como isso pode dificultar a interação dos usuários, caso desejem testar imagens que estão salvas em seu computador, o código foi modificado para exibir um link para uma API do Imgur,

⁹ Demonstração em passo a passo no Youtube, disponível em:
<<https://www.youtube.com/watch?v=0GpF39U9iaQ>>. (MAZON, 2018)

¹⁰ Repositório com código para implantação do modelo no GitHub, disponível em:
<<https://github.com/smazon/visual-recognition>>. (MAZON, 2018)

desenvolvida com base em outro repositório do GitHub^{11,12}. O Imgur é um site que gera uma URL temporária para a imagem enviada. Então, a página foi editada com instruções para auxiliar na utilização da mesma, além de uma reestruturação do layout, onde foram alterados textos e imagens da página, para torná-la característica ao caso de uso de metalografia.

A integração do modelo criado com a página web seguiu o passo a passo disponibilizado na demonstração do Watson™ Visual Recognition no Github. Foi utilizado um outro serviço da IBM, chamado Node-RED, uma ferramenta de programação em blocos que facilita a utilização da linguagem JavaScript. É possível criar uma instância do Node-RED na conta gratuita da IBM Cloud™, concentrando todos os serviços utilizados neste trabalho em uma mesma conta. O fluxo dos blocos utilizados para realizar a integração e a interface do Node-RED estão retratados na figura abaixo:

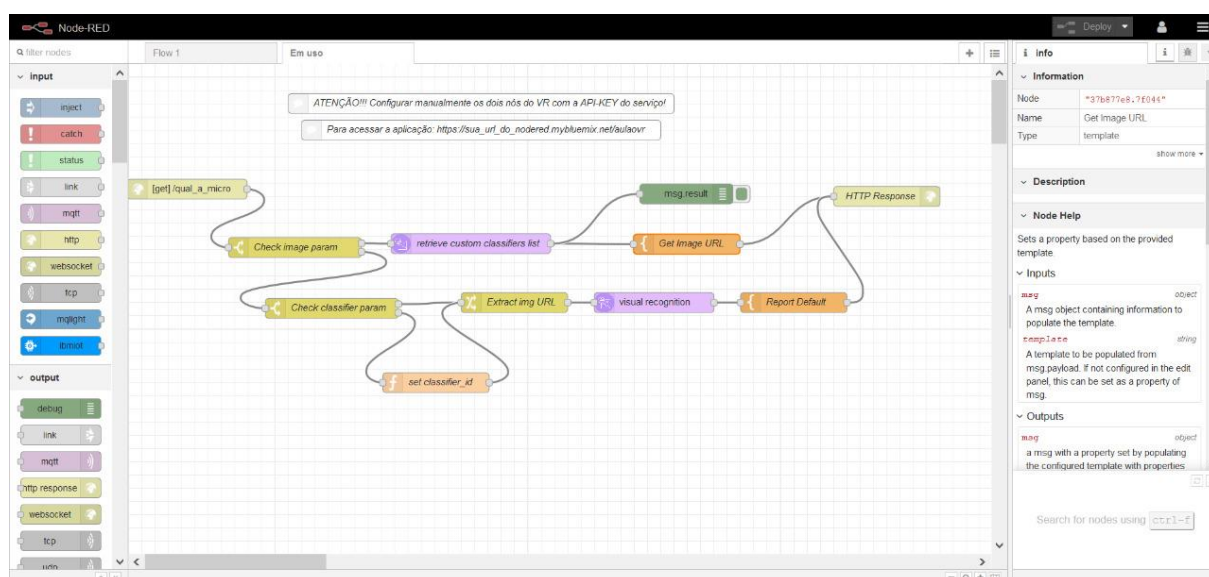


Figura 22 – Fluxo dos blocos de programação utilizados na interface do Node-RED

Fonte: Elaboração própria, 2019.

Seguindo o caso de uso definido na fase de Design e Planejamento (fase 1 do ciclo de AI), a aplicação foi levada aos alunos da disciplina de metalografia (PMT3402: Metalografia e Tratamentos Térmicos dos Metais – 2019; Escola

¹¹ Repositório com código no GitHub, disponível em: <<https://github.com/carry0987/Imgur-Upload>> (YUN, 2017).

¹²Vídeo com passo a passo no Youtube, disponível em: <<https://www.youtube.com/watch?v=qmNbZmBOaGM>> (CODE TUBE, 2017).

Politécnica da USP, Departamento de Engenharia Metalúrgica e de Materiais), para que forneçam uma boa massa de dados e para que a página lhes seja útil como ferramenta de estudo no decorrer do semestre. A aplicação pode ser acessada pelo seguinte link: <https://isaperini-poli.mybluemix.net/qual_a_micro>. Conforme já descrito, a página web foi desenvolvida a partir do código base fornecido no repositório do Github da demonstração do Watson™ Visual Recognition.

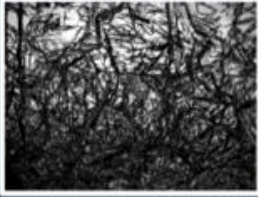
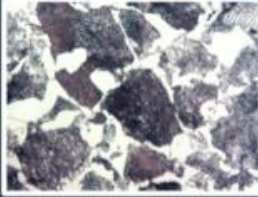

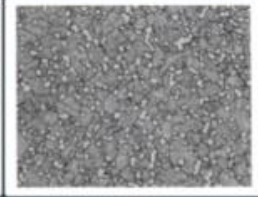
Além disso, de forma a coletar os feedbacks dos usuários de maneira gratuita, foi utilizado um formulário no Google Forms, onde o usuário pode dar o feedback sobre a aplicação, além de inserir a imagem no formulário, o que permite que a mesma seja aproveitada para retreinar o modelo. O link para o formulário foi incluído na página de resposta da aplicação. O formulário pode ser acessado pelo seguinte endereço: <<https://forms.gle/wHifBT11GiTtKjKu7>>. Foi perguntado sobre as condições da imagem, como aumento, ataque, microestrutura e material da amostra, além de incluir uma pergunta sobre autorização do uso da imagem enviada para retreinar o modelo. Os dados de resposta serão analisados posteriormente para verificar o desempenho do modelo e refiná-lo, de forma iterativa, conforme sugerido pela metodologia do Ciclo de AI.

As figuras a seguir ilustram o resultado final da página:

QUAL A MICRO?

BEM VINDO AO MEU APLICATIVO WEB DE RECONHECIMENTO DE IMAGENS!

ESTE É UM CLASSIFICADOR TREINADO PARA RECONHECER OS SEGUINTE MICROCONSTITUINTES EM UMA MICROESTRUTURA DE UM AÇO:

Martensite em Placas Ferrita e Perlita Ferrita Carbonites

CLASSIFICADORES DE IMAGEM CONECTADOS

Modelo	ID do Modelo	Status
Default Watson Classifier	default	ready
Reconhecimento de microconstituintes de aço 2	Reconhecimento de microconstituintes de aço 2	ready

RECOMENDAÇÕES:

- Este classificador foi treinado apenas para analisar a microestrutura de AÇOS.
- Procure enviar imagens obtidas com pelo menos 200x de aumento. O resultado será mais preciso se sua imagem tiver sido obtida com um aumento de 500x ou mais.
- Imagens com proporção próxima a 1:1 apresentarão melhores resultados.
- Este classificador foi treinado para imagens produzidas com o ataque químico de NITOL. Como outros ataques químicos produzem imagens muito diferentes entre si, procure imagens de aços atacados com nital para obter melhores resultados.
- O classificador irá tentar encaixar sua imagem nas classes para as quais foi treinado, a partir de similaridade entre a imagem inserida e as do banco de treinamento.
- Você deve inserir a URL de sua imagem. Caso sua imagem esteja salva no seu computador, [clique aqui](#) para obter uma URL para a mesma.

PARA ANALISAR UMA IMAGEM, INSIRA A URL (TERMINANDO EM .JPG OU .PNG) E O ID DO MODELO ABAIXO.

URL da Imagem: ID do Modelo:

CLASSIFICADOR DESENVOLVIDO POR ISABELLA CASEMIRO PERINI
Email: isacperini@gmail.com
Trabalho de formatura em Engenharia de Material pela a Escola Politécnica da USP

Figura 23 – Página inicial da aplicação. Em rosa, está o link que direciona o usuário para a página de geração de URL via Imgur.

Fonte: Elaboração própria, 2019.

The screenshot shows a web browser window with the URL `https://icperini.mybluemix.net/qual_a_micro?url=https%3A%2F%2Fwww.carpentertechnology.com/globalassets/alloy-techzone/technical-solutions/technical-articles/TA29029_FIG2.JPG`. The page has a dark blue header with the 'pmtpoli' logo on the left, the title 'QUAL A MICRO?' in the center, and the 'IBM' logo on the right. Below the header, the main heading is 'WATSON VISUAL RECOGNITION'. Underneath, it says 'IMAGEM ANALISADA: HTTPS://WWW.CARPENTERTECHNOLOGY.COM/GLOBALASSETS/ALLOY-TECHZONE/TECHNICAL-SOLUTIONS/TECHNICAL-ARTICLES/TA29029_FIG2.JPG'. A square image of a microscopic view of carbon particles is displayed. Below the image, the section 'RESULTADOS' contains a table with two columns: 'Classe' and 'Pontuação'. The table has one row with the value 'Carbonetos' and a score of '0.883'. Below the table, there is a text prompt 'POR FAVOR, AJUDE A MELHORAR O MODELO RESPONDENDO ESTE FORMULÁRIO.' with the word 'FORMULÁRIO' in pink. A blue button labeled 'Retornar' is positioned below the text. At the bottom of the page, a footer contains the text: 'CLASSIFICADOR DESENVOLVIDO POR ISABELLA CASEMIRO PERINI', 'Email: isacperini@gmail.com', and 'Trabalho de formatura em Engenharia de Materiais pela a Escola Politécnica da USP'.

Classe	Pontuação
Carbonetos	0.883

Figura 24 – Página de resultados da aplicação. O formulário do Google Forms pode ser acessado clicando em “este formulário”, em rosa.

Fonte: Elaboração própria, 2019.

3.3.5 Evolução

O modelo passou por avaliações de maneira iterativa, percorrendo todas as fases até que a precisão e acurácia desejadas fossem atingidas, contando também com a adição de novas classes ao modelo. Isto deu início ao denominado neste trabalho como “segundo ciclo de inteligência artificial”. Assim, com os resultados da fase 4 (inferência) em mãos, foi possível avaliar o próximo passo de refino do modelo, iniciando um novo ciclo de AI.

Após a inserção da Ferrita e refino da classe Martensita, prévias ao lançamento do modelo em ambiente de produção, foram testadas algumas imagens ainda não utilizadas do banco. O modelo foi capaz de reconhecer corretamente algumas microestruturas de martensita em ripas (a qual ainda não havia sido treinada) como Martensita, apenas com a base existente de martensita em placas. Adicionalmente, já no ambiente de produção, algumas das imagens enviadas pelos usuários exibiram martensita em ripas, e foram classificadas também como a classe Martensita. Dessa forma, a maior mudança decidida para refinar o classificador foi a de inserir novas imagens de martensita em ripas (baixo carbono) no modelo, de modo a permitir a distinção da martensita em placas, que costuma apresentar austenita retida.

Analisando os erros cometidos na classificação das imagens inseridas pelos usuários, optou-se por incluir algumas novas imagens também nas classes pré-existentes. O classificador foi desenvolvido em um novo modelo, para não prejudicar o que já estava em produção, evitando erros na página web. Para tanto, é possível utilizar as mesmas imagens previamente inseridas, que ficam armazenadas na conta da IBM Cloud™ e portanto possuem fácil acesso. Contudo, como parte das imagens utilizadas na primeira versão do modelo continha proporções inadequadas (muito diferentes de 1:1), algumas foram manipuladas, antes de serem inseridas no novo modelo, tanto imagens de treinamento quanto de testes. Os exemplos previamente sorteados foram mantidos em seus *sets* (treinamento ou teste), mesmo sendo cortados para adequação da dimensão, o que gera novas imagens. Após o corte das imagens, o banco de treinamento passou a ter 462 e o de teste 115 imagens. Um total de 259 figuras ainda não haviam sido utilizadas ou foram obtidas com o teste com usuários. Destas, 208 foram destinadas para o banco de treinamento e 51 para o de teste. A tabela abaixo sintetiza a adição das novas figuras, incluindo as destinadas para representar a martensita em ripas:

Tabela 3 – Resumo da quantidade de novas imagens adicionadas na segunda versão do modelo

Classe	Total de novas imagens	Novas imagens treinamento	Novas imagens testes	Total de imagens treinamento	Total de imagens testes
Ferrita e Perlita	57	43	14	162+43= 260	37+14 = 51
Martensita (placas)	31	27	4	115+27= 142	31+4 = 35
Carbonetos	14	11	3	99+11= 110	24+3 = 27
Ferrita	10	9	1	86+9 = 95	23+1 = 24
Martensita (ripas)	147	118	29	118	29
Total:	259	208	51	725	166

Fonte: Elaboração própria, 2019.

Muitas imagens de martensita foram obtidas, porém boa parte não era bem definida, com resolução baixa, além de algumas retratarem também outros microconstituintes. Pela dificuldade em diferenciar os casos onde a martensita encontra-se completamente na morfologia de ripas dos casos onde a morfologia é mista, optou-se por completar a classe martensita com as imagens disponíveis, já que todas as morfologias se encaixam na classe geral de Martensita. Dessa forma, foram selecionadas 147 novas imagens de martensita (118 para treinamento e 29 para testes), predominantemente em ripas, mas algumas mistas, para montar a nova classe Martensita (M). As demais 142 imagens de treinamento de martensita em placas também serão adicionadas à nova classe.

Como a morfologia em placas é mais facilmente reconhecida, além de conter a presença de austenita retida, uma nova classe será criada apenas para esta morfologia, denominada Martensita&Austenita (MA). Esta classe funciona como uma espécie de subclasse da classe geral Martensita. Porém, as imagens de martensita em placas estarão duplicadas em ambas as classes, para que não sejam utilizadas imagens representativas de martensita como exemplos negativos em nenhum dos casos de treinamento, ou seja, as imagens de martensita em placas da classe Martensita&Austenita não serão utilizadas como exemplos negativos no treinamento da classe Martensita, mesmo sendo classes diferentes. O caso oposto também é válido, porém, as imagens de martensita em ripas serão contraexemplos para a classe de Martensita&Austenita, que contém morfologia de placas. Vale ressaltar

que as imagens duplicatas devem ser exatamente as mesmas imagens, com mesmo nome, tamanho e extensão. Desse modo, o classificador reconhece que não deve usar estas imagens como exemplos negativos, mesmo que estejam em classes diferentes.

Quanto aos testes, são 29 imagens para martensita em ripas (ou mista) e 35 para martensita em placas, com austenita retida. É esperado que o modelo não aponte a classe MA para as 29 imagens de martensita em ripas, mas pode apontar a classe M para qualquer uma delas. Isto ocorre, pois, as imagens de martensita em placas estão presentes nas duas classes, desta forma, a classe Martensita&Austenita funciona como uma espécie de subclasse da classe Martensita.

O novo modelo foi nomeado como “Qual a micro”, para combinar com o nome da página web. As classes foram criadas de acordo com a tabela 3, sendo o sorteio das imagens realizados no Excel, conforme descrito na seção 3.3.3.1. O modelo apresenta agora 5 classes e 867 imagens (725 únicas mais 142 duplicadas de martensita em placas). Nota-se que as imagens em miniatura mostradas na figura abaixo são as mesmas para as classes Martensita e Martensita&Austenita, pois as imagens estão duplicadas nestas classes, conforme já explicado.

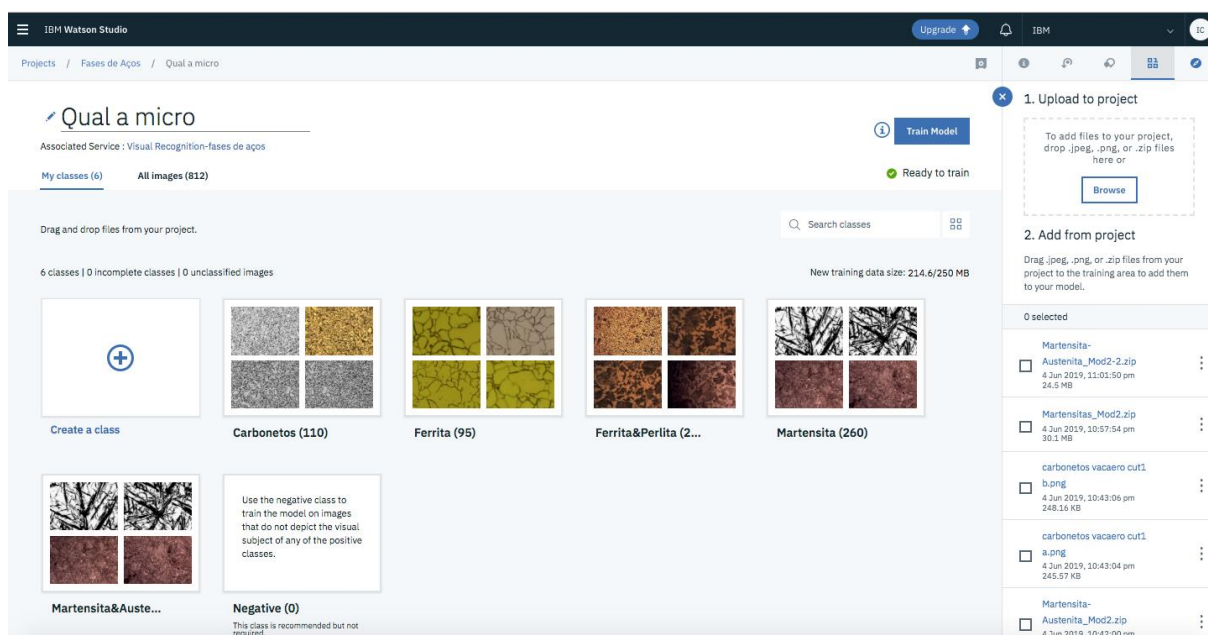


Figura 25 – Novo modelo desenvolvido com mais imagens e mais classes

Fonte: Elaboração própria, 2019.

O treinamento do modelo levou aproximadamente 50 minutos, e todas as classes foram adicionadas de uma vez, totalizando 214MB de armazenamento para as 867 imagens inseridas. Os resultados dos testes serão apresentados no capítulo de resultados.

4 RESULTADOS E DISCUSSÕES

4.1 PROVA DE COMPATIBILIDADE

Para as imagens que estavam na classe teste de ferrita e perlita (classe Ferrita&Perlita – FP), o modelo pode identificar com precisão o pertencimento das imagens à classe FP, sendo o menor índice de confiança 0,89, obtido apenas em uma imagem. O IC foi de 0,92 para todas as demais, valor bastante alto, considerando a escala de 0 a 1. Já a classe negativa apresentou resultados menos precisos, o que pode ser explicado pela baixa representatividade de imagens para as diferentes microestruturas que foram inseridas na classe negativa do modelo. Além disso, houve uma alta variabilidade entre as poucas micrografias inseridas no treinamento, que apresentavam pouca semelhança entre si, provavelmente dificultando a etapa de *feature engineering* do algoritmo. Este problema é semelhante ao ocorrido no trabalho de Chowdhury *et al.* (2016) na avaliação da tarefa de seleção das características (*feature selection*), onde não foi possível determinar ou distinguir o melhor método de *machine learning* para realização desta etapa, dada a alta variabilidade da classe negativa.

Abaixo, uma figura que ilustra a interface de testes bem como alguns dos resultados desta etapa.

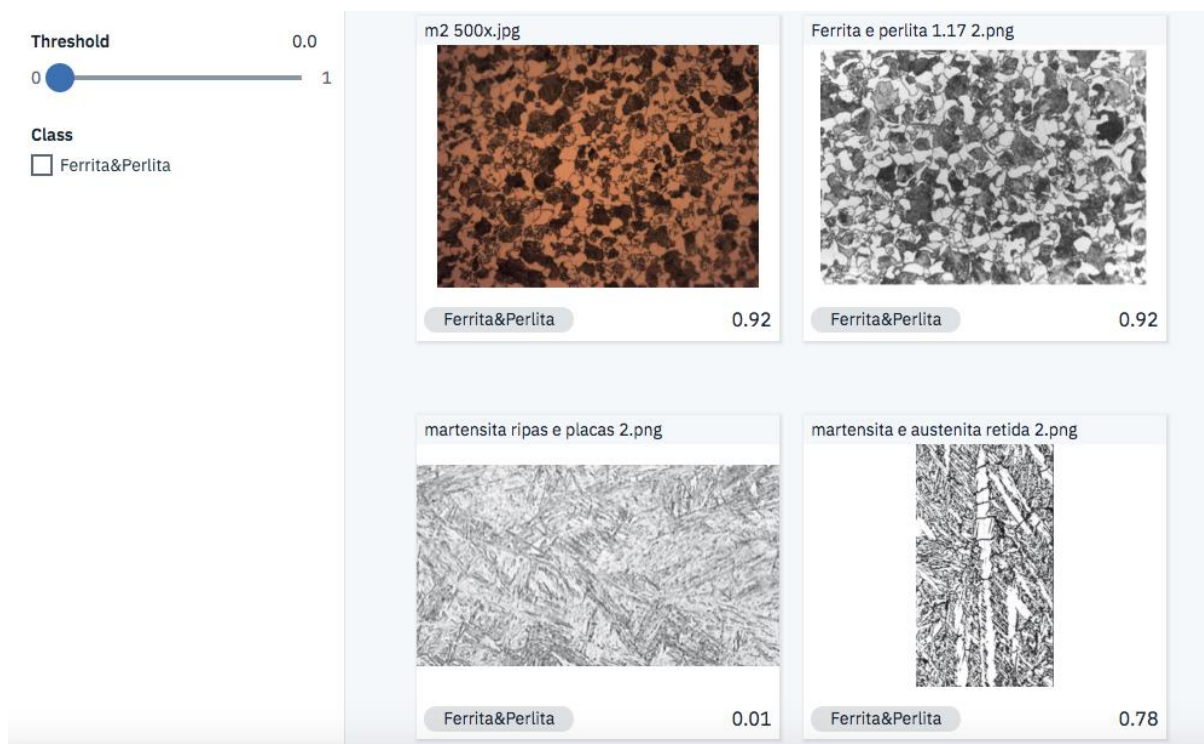


Figura 26 – Resultado de algumas das imagens de teste desta etapa. As duas imagens superiores possuem microestrutura de ferrita e perlita, enquanto as duas inferiores são representativas de martensitas

Fonte: Elaboração própria, 2019.

Apenas uma classe é exibida, pois a classe negativa não é entendida como uma classe propriamente dita, serve apenas de auxílio nas demais classificações. Na figura, apenas a imagem “martensita e austenita retida 2.png” não foi classificada corretamente, apresentando um índice de confiabilidade alto para a classe Ferrita&Perlita, a qual não está presente na imagem.

Dados os resultados positivos, obtidos com uma baixa massa de dados, conclui-se que os algoritmos do Watson™ Visual Recognition são capazes de reconhecer imagens de microestrutura, determinando a continuidade deste projeto. Espera-se que a adição de novas classes promovam melhoria expressiva nos resultados.

4.2 PRIMEIRO CICLO DE INTELIGÊNCIA ARTIFICIAL

4.2.1 Treinamentos da primeira versão do modelo

Foram avaliados a acurácia e o índice de confiabilidade. Os valores fornecidas pelo IC são comparáveis, ou seja, é possível comparar as pontuações de classes customizadas, seja na mesma imagem ou em imagens diferentes. A classe com maior IC teve probabilidade calculada de aparecer na imagem maior do que as demais. No entanto, mais de uma classe pode estar presente na imagem inserida, o que resulta em um abaixamento do IC. A acurácia total do modelo foi calculada através do valor total de acertos dividido pela quantidade de imagens de teste. O IC médio de cada classe foi calculado através da média do IC referente a classe analisada nas imagens representativas desta classe, incluindo nas quais a classificação foi errada.

Como as classes foram adicionadas uma a uma, foi possível avaliar os parâmetros do modelo a cada etapa. A primeira rodada de testes foi entre as classes Ferrita&Perlita (FP) e Martensita (M). Os resultados gerais estão exibidos na tabela abaixo:

Tabela 4 – Resultados da rodada de teste entre Ferrita&Perlita e Martensita (rodada 1)

Classes	Total de Imagens de Treinamento	Total de Imagens de Teste	Total de Acertos	Acurácia	Índice de Confiabilidade Médio
Ferrita&Perlita	149	37	37	1,000	0,920
Martensita	73	18	16	0,889	0,854
TOTAL	222	55	53	0,964	-

Fonte: Elaboração própria, 2019.

Os resultados referentes a classe Martensita foram menos satisfatórios que os da classe Ferrita&Perlita. Isso pode ter ocorrido devido a quantidade menor de imagens utilizadas no treinamento da classe Martensita.

Contudo, é possível avaliar o índice de confiabilidade de maneira isolada. O programa calcula os índices de um modo que o valor 0,5 seja um bom limite de decisão (*threshold*), quando necessário. Assim, pode-se avaliar a quantidade de imagens onde a classificação da classe errada foi acima de 0,5. Dessa forma, tem-se três imagens classificadas manualmente como Martensita que apresentaram inconsistências, sendo que duas foram percebidas de maneira equivocada pelo programa, conforme tabela abaixo:

Tabela 5 – Resultados das imagens com pior classificação na rodada de teste 1

#	Nome	Classe	Modelo			
			Classe 1	Classe 2	IC Classe 1	IC Classe 2
1	A01_200x 1	Martensita	FP	M	0,87	0,26
2	A03_200x 1 1	Martensita	M	FP	0,68	0,65
3	martensita e austenita aula4 4.jpeg	Martensita	FP	M	0,69	0,63
4	ferrita e perlita 23.png	Ferrita&Perlita	FP	M	0,92	0,13

Fonte: Elaboração própria, 2019.

Percebe-se que o pior resultado foi o da imagem 1, representativa de martensita, onde o índice de confiabilidade para a classe Martensita foi 0,26 (menor do que 0,5) e para a classe Ferrita&Perlita foi de 0,87, confiabilidade bastante elevada. Caso o limite de decisão (também chamado de *threshold*) fosse configurado para 0,5, a imagem 1 seria erroneamente classificada como Ferrita&Perlita. Já a imagem 2 apresentou classificação correta como Martensita, contudo o índice de confiabilidade da classe Ferrita&Perlita apresentou-se elevada, acima de 0,5. A imagem 3 apresentou índices de confiabilidade semelhantes ao da imagem 2, porém foi classificada erroneamente como Ferrita&Perlita. A imagem 4 foi a imagem do conjunto de teste da classe Ferrita&Perlita que apresentou maior IC para a classe Martensita, ainda assim, muito baixo.

Para entender a lógica utilizada pelo modelo nesta classificação, as três primeiras imagens foram avaliadas, sendo produzidas novas imagens a partir delas. Para a figura 1 e 2, o modelo se confundiu, possivelmente por uma questão de escala/resolução das imagens. Foram produzidas novas imagens de teste cortando

partes das imagens originais. O resultado foi bastante satisfatório, conforme imagem abaixo:

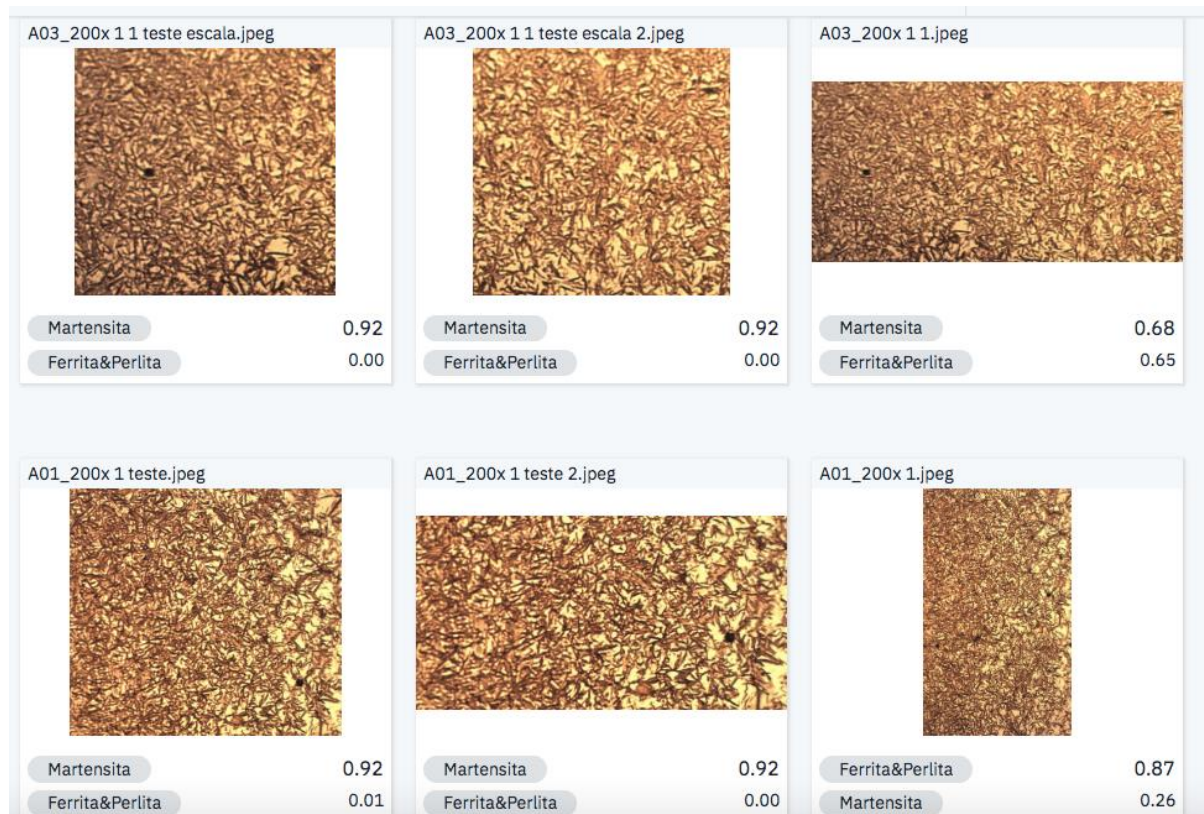


Figura 27 – Resultados dos testes com manipulação das imagens 1 e 2

Fonte: Elaboração própria, 2019.

Portanto, é provável que a qualidade das imagens originais 1 e 2 não estivesse adequada para identificação, ou mesmo a escala utilizada não permitiu diferenciação adequada. Ainda, a dimensão das imagens (retangular) pode estar sendo utilizada como fator de classificação ou prejudicando o reconhecimento, pois o Visual Recognition redimensiona as imagens para o formato quadrado (está otimizado para imagens de resolução 224 x 224 pixels). Dadas estas hipóteses, uma possível ação seria adicionar imagens com características semelhantes no treinamento do modelo. Já para a imagem 3, não foi possível identificar o fator que causou a má classificação, indicando que o modelo ainda pode ser aperfeiçoado.

Para melhorar o modelo, a imagem 3 e imagens modificadas da imagem 1 e 2 foram incluídas no modelo. A classe martensita passou a ter neste momento 77 imagens (4 novas adicionadas). Em seguida, as imagens 1 - 4 foram novamente inseridas na interface de testes para verificar se houve diferença na classificação do

modelo. Deve-se notar que a imagem 3 foi inserida no treinamento, portanto o teste com a mesma imagem não é recomendado.

Tabela 6 – Resultados dos testes com as imagens de pior classificação após adição de novas 4 imagens a classe Martensita

#	Nome	Classe	Modelo			
			Classe 1	Classe 2	IC Classe 1	IC Classe 2
1	A01_200x 1	Martensita	FP	M	0,88	0,23
2	A03_200x 1 1	Martensita	M	FP	0,81	0,43
3	martensita e austenita aula4 4.jpeg	Martensita	M	FP	0,91	0,05
4	ferrita e perlita 23.png	Ferrita&Perlita	FP	M	0,91	0,08

Fonte: Elaboração própria, 2019.

Conforme esperado, a imagem 3 apresentou melhoria significativa em seu resultado, pois se trata de uma imagem “conhecida”, já que foi adicionada ao banco de treinamento. Já a imagem 1 não apresentou melhoria, indicando que a escala e dimensão ainda são fatores de atenção. A imagem 2 possui escala e dimensões semelhantes a da imagem 1, porém o resultado apresentou melhorias, diminuindo o IC da classe Ferrita&Perlita para 0,43, valor abaixo de 0,5, além de aumentar o IC da classe Martensita para 0,81. A imagem 4 também teve resultados positivos, com uma redução no IC para Martensita. Estes resultados indicam que o modelo pode apresentar mudanças significativas na classificação mesmo com a adição de uma baixa quantidade de imagens, no caso, apenas 4.

A próxima classe adicionada e testada foi a classe Carbonetos (C). Após o treinamento do modelo, foram realizados testes com todas as imagens das classes já inseridas destinadas para este fim, totalizando 79 imagens de teste (24 da classe Carbonetos, 18 da classe Martensita e 37 da classe Ferrita&Perlita). Os resultados desta rodada de teste estão compilados na tabela abaixo:

Tabela 7 – Resultados da rodada de teste entre Ferrita&Perlita, Martensita e Carbonetos (rodada 2)

Classes	Total de Imagens de Treinamento	Total de imagens de Teste	Total de Acertos	Acurácia	Índice de Confiabilidade Médio
Ferrita&Perlita	149	37	32	0,865	0,796
Martensita	77	18	17	0,944	0,843
Carbonetos	96	24	24	1,000	0,910
TOTAL	322	79	73	0,924	-

Fonte: Elaboração própria, 2019.

Para a classe Carbonetos, o modelo identificou corretamente todas as imagens inseridas, com IC de 0,91 em todas as imagens. Apenas uma imagem apresentou IC de 0,01 para a presença de martensita, o que pode ser desconsiderado pelo índice ser muito baixo. Para a classe Martensita, o modelo classificou errado apenas uma imagem, além de outras duas que apresentaram ICs maiores que 0,2 para classes que não estavam presentes na imagem. Já para as imagens de ferrita e perlita, o modelo classificou 5 imagens erradas, além de apresentar ICs maiores que 0,4 para classes que não estavam presentes nas imagens. Algumas das imagens que apresentaram erros na classificação foram as mesmas problemáticas no teste anterior, com as classes Ferrita&Perlita e Martensita. A tabela abaixo retrata os casos em que o resultado não foi satisfatório, conforme descrito neste parágrafo.

Tabela 8– Resultados dos testes com as imagens de pior classificação na rodada de teste 2

			Modelo					
			Classe			IC		
#	Nome	Classe	1	2	3	Classe 1	Classe 2	Classe 3
1	A01_200x 1	Martensita	C	FP	M	0,89	0,05	0,05
2	A03_200x 1 1	Martensita	M	C	FP	0,62	0,47	0,27
3	martensita e austenita aula4 4 teste 4.jpeg	Martensita	M	C	-	0,86	0,23	
4	ferrita e perlita 3.53 3	Ferrita&Perlita	C	FP	-	0,89	0,11	
5	ferrita e perlita 4.png	Ferrita&Perlita	C	FP	M	0,88	0,15	0,01
6	ferrita e perlita 19.png	Ferrita&Perlita	C	FP	-	0,87	0,18	
7	ferrita e perlita 23.png	Ferrita&Perlita	C	FP	M	0,90	0,02	0,01
8	ferrita e perlita 24 2 ousado	Ferrita&Perlita	FP	C	-	0,68	0,60	
9	m3 1000x.jpg	Ferrita&Perlita	FP	C	-	0,79	0,41	
10	ferrita e perlita grossa mhb 75	Ferrita&Perlita	FP	C	M	0,75	0,44	0,08
11	ferrita e perlita nat 8 zoom2	Ferrita&Perlita	C	FP	-	0,72	0,55	

Fonte: Elaboração própria, 2019.

Em seguida, a figura 28 demonstra as imagens utilizadas nesta etapa.




Figura 28 – Resultados obtidos na classificação das imagens da rodada de teste 2. Relacionando com a tabela, da esquerda para a direita, as imagens são: (1) 10, 11, 4, 6; (2) 8, 9, 5, 7; (3) 1, 2, 3.

Fonte: Elaboração própria, 2019.

A imagem 1 já havia apresentado problemas na classificação no teste anterior, dada a dimensão e o baixo aumento da imagem. Utilizando uma imagem manipulada a partir desta, onde foi recortada a imagem para aumentar o zoom e equilibrar as proporções da imagem (a original era retangular, o recorte aproximou de um quadrado), a classificação pelo modelo foi muito precisa, indicando IC de 0,91 para a classe Martensita e de apenas 0,02 para a classe Carbonetos, conforme figura abaixo:



Figura 29 – Resultados obtidos com a imagem 1 cortada

Fonte: Elaboração própria, 2019.

A imagem 2, também de baixa escala e de proporção retangular, foi tratada da mesma forma, ainda que os resultados do IC para as classes que não a correta tenham sido menores que 0,5. O recorte inserido apresentou os mesmos resultados que o recorte da imagem 1. Isto indica que a escala das imagens de teste, bem como a proporção são importantes e devem ser, preferencialmente, superior a um aumento de 200x e mais próxima de um quadrado (1:1). A imagem 6 também possui proporção retangular. Ao realizar o mesmo teste que nas imagens 1 e 2, o modelo classificou corretamente, indicando um IC de 0,90 para a classe Ferrita&Perlita e apenas 0,05 para a classe Carbonetos, reforçando a hipótese de que a proporção das imagens deve ser mais próxima de um quadrado (esta é uma das boas práticas indicadas na documentação do Watson™ Visual Recognition). A imagem 8, apesar de ter classificado corretamente como Ferrita&Perlita, o IC para a classe Carbonetos foi elevado, maior que 0,5. Esta imagem também apresentou o problema de proporção retangular e resolução ligeiramente baixa. Ao inserir um recorte da imagem quadrado, o reconhecimento foi melhor, com IC de 0,90 para a classe Ferrita&Perlita e 0,06 para Carbonetos. O resultado das imagens 4, 5 e 7 foram menos esperados, pois as imagens não possuem problemas de escala ou proporção tão claros. Contudo, a imagem 4 possui resolução baixa, além do teor de perlita na

imagem ser alto, formando colônias que poderiam ser confundidas com carbonetos pelo modelo, ainda mais com a escala não tão alta. A imagem 5 também possui problemas de resolução, sendo a imagem levemente desfocada. Foi criada uma cópia da imagem 5, alterando-se a propriedade “*sharpness*”, para melhorar a resolução da mesma. Isto melhorou o IC do modelo para a classe Ferrita&Perlita de 0,15 para 0,54, mas o da classe Carbonetos continuou superior, com valor de 0,72. Um novo recorte na imagem tratada funcionou como um *zoom* e alcançou classificação correta para a imagem, o que reforça que o modelo avalia a imagem inserida como um todo, de modo que a baixa resolução combinada com uma escala inadequada podem causar resultados errados. A figura abaixo retrata os testes realizados na imagem 5:

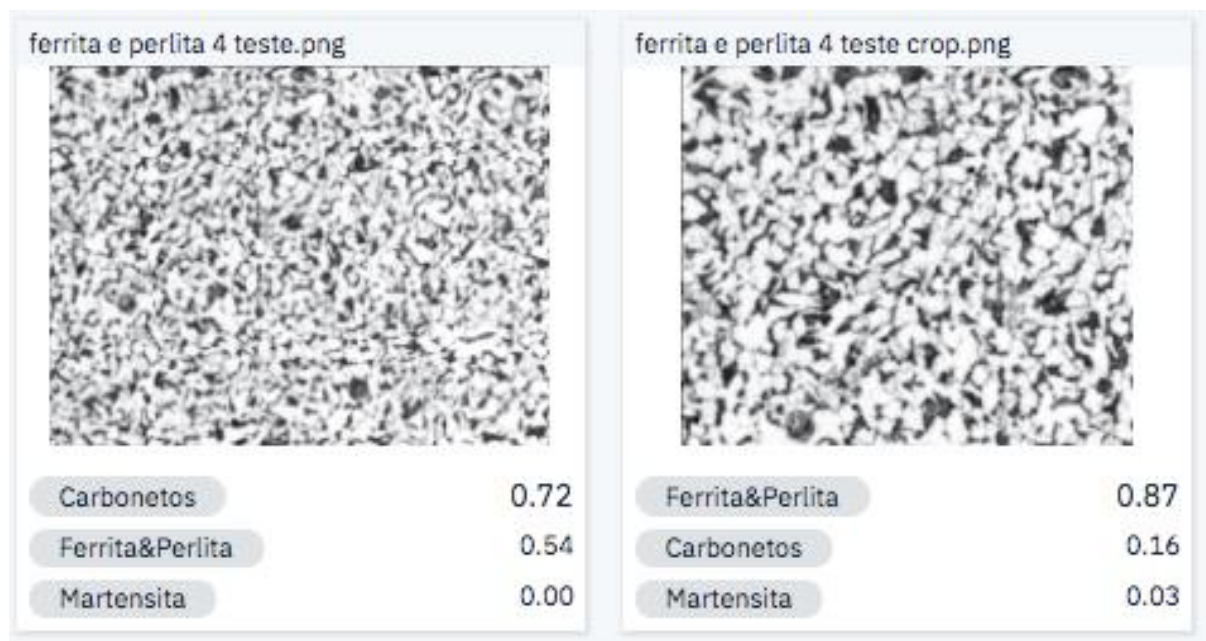


Figura 30 – Testes realizados com a imagem 5 manipulada: (a) ajuste de *sharpness* e (b) recorte da imagem em (a).

Fonte: Elaboração própria, 2019.

Para a imagem 7, não foi possível identificar o motivo da classificação errada. A imagem 11 apresentou os mesmos problemas de resolução que a imagem 5, pois estava desfocada. Ajustando o “*sharpness*”, foi possível obter classificação correta, com IC de 0,87 para FP e 0,17 para C. As imagens 3, 9 e 10 não possuem nenhum dos problemas citados no parágrafo e foram classificadas corretamente, sendo o resultado dos ICs obtidos, provavelmente, devido a morfologia da microestrutura

registrada. Contudo, o valor de IC para as demais classes é inferior a 0,5, valor considerado como limite de classificação.

Como não se sabe precisamente qual será a qualidade das imagens inseridas pelos usuários do modelo, ainda não faz sentido incluir mais imagens de acordo com os problemas de qualidade descritos no parágrafo anterior. Caso sejam enviadas pelos usuários muitas imagens com baixo foco, talvez seja interessante treinar o modelo nestas situações, ou orientar os usuários a inserir fotos de maior qualidade.

A próxima classe inserida no modelo foi a Ferrita (F), com 80 imagens para treinamento e 20 para testes, sorteadas no Excel. Após o treinamento, uma nova rodada de testes foi realizada com todas as 99 imagens de teste (20 da classe Ferrita, 24 da classe Carbonetos, 18 da classe Martensita e 37 da classe Ferrita&Perlita). Os resultados desta rodada de teste estão exibidos na tabela abaixo:

Tabela 9 – Resultados da rodada de teste entre Ferrita&Perlita, Martensita, Carbonetos e Ferrita (rodada 3)

Classes	Total de Imagens de Treinamento	Total de imagens de Teste	Total de Acertos	Acurácia	Índice de Confiabilidade Médio
Ferrita&Perlita	149	37	31	0,838	0,791
Martensita	77	18	17	0,944	0,864
Carbonetos	96	24	24	1,000	0,906
Ferrita	80	20	19	0,950	0,866
TOTAL	402	99	91	0,919	-

Fonte: Elaboração própria, 2019.

Nota-se que, conforme mais classes foram adicionadas ao modelo, menor foi a acurácia, com um decréscimo de 0,964 inicialmente para 0,919 ao final dos testes da classe ferrita. Isso ocorre pois pode haver semelhança entre as classes criadas, o que torna a predição do modelo mais complexa. Contudo, o decréscimo da acurácia não impede que o modelo seja levado para a fase de inferência, já que o valor desejado como objetivo foi alcançado (60% de acurácia). Ainda, vale ressaltar que o maior decréscimo da acurácia ocorreu na adição da classe Carbonetos, terceira classe inserida, conforme exibido na tabela abaixo:

Tabela 10 – Comparação da acurácia geral com cada classe adicionada

Quantidade de classes	Acurácia geral	Decréscimo da acurácia
2	0,964	
3	0,924	0,04
4	0,919	0,005
Total		0,045

Fonte: Elaboração própria, 2019.

Possivelmente, esta queda na acurácia ocorreu pois a classe Carbonetos foi montada com muitas imagens obtidas em aula, para completar o número necessário de imagens para treinamento e teste. Ainda, as imagens de aula foram cortadas mais vezes que as demais utilizadas, o que pode artificialmente aumentar a escala na interpretação do modelo, já que todas as figuras são redimensionadas para 224 x 224 pixels na avaliação. Além disso, foi necessário encontrar imagens onde a matriz não estivesse resolvida, já que isto poderia prejudicar o treinamento das demais classes, principalmente se a matriz for representativa de uma delas, uma vez que o treinamento ocorre de forma binária, “todos contra um”, empregando todas as classes como negativa da que está sendo treinada (IBM CLOUD, 2019).

Outro fato interessante foi a pequena redução do IC máximo obtido, que inicialmente era de 0,92 e passou a ser 0,91, o que também é compatível com a explicação do decréscimo da acurácia, pois uma maior quantidade de classes com alguma semelhança entre si pode levar a tais resultados por tornarem a classificação mais complexa. A redução do IC máximo também ocorreu após a adição da classe Carbonetos, e manteve-se o mesmo com a posterior adição da Ferrita, o que sugere que a classe Carbonetos possui fotos que podem apresentar semelhanças com as fotos presentes nas demais classes do modelo.

A tabela a seguir mostra os resultados obtidos após a inserção e treinamento da classe Ferrita, destacando as imagens que apresentaram problemas na classificação.

Tabela 11 – Resultados dos testes com as imagens de pior classificação na rodada de teste 3

			Modelo							
			Classes				Índice de Confiabilidade (IC)			
#	Nome	Classe	1	2	3	4	Classe 1	Classe 2	Classe 3	Classe 4
1	A01_200x 1	Martensita	C	M	FP	F	0,85	0,18	0,04	0,01
2	ferrita e perlita 3.53 3	Ferrita&Perlita	C	FP	-	-	0,90	0,05		
3	ferrita e perlita 4.png	Ferrita&Perlita	C	FP	-	-	0,76	0,46		
4	ferrita e perlita 19.png	Ferrita&Perlita	C	FP	-	-	0,75	0,49		
5	ferrita e perlita 23.png	Ferrita&Perlita	C	FP	-	-	0,90	0,01		
6	ferrita e perlita 24 2 ousado	Ferrita&Perlita	C	FP	-	-	0,81	0,37		
7	200x v2.jpg	Ferrita&Perlita	FP	C	-	-	0,87	0,17		
8	aço - 1000x - nital 2% - A3.jpg	Ferrita&Perlita	FP	F	C	-	0,81	0,31	0,05	
9	aço - 1000x - nital 2% - A5.jpg	Ferrita&Perlita	FP	F	C	-	0,85	0,21	0,02	
10	ferrita e perlita grossa mhb 75	Ferrita&Perlita	FP	C	M		0,57	0,53	0,25	
11	ferrita e perlita nat 8 zoom2	Ferrita&Perlita	C	FP	-	-	0,81	0,35		
12	ferrita do it 224 e carbonetos 3	Ferrita	F	C	FP	-	0,82	0,25	0,08	
13	ferrita e cementita 4 2	Ferrita	F	C	M	FP	0,86	0,18	0,01	0,01
14	ferrita e cementita 4 3	Ferrita	C	F	-	-	0,86	0,50		
15	recristalizacao ferrita 17.26 4 cut2	Ferrita	F	C	M	-	0,67	0,58	0,02	

Fonte: Elaboração própria, 2019.

No total, 8 imagens foram classificadas com equívoco (imagens 1 a 6, 11 e 14). As imagens 7 a 9, 12 e 13 foram classificadas corretamente, porém apresentaram IC maiores que 0,15, mas bem menores que 0,5, o que não prejudica a classificação geral do modelo, apenas serve de ponto de atenção para as próximas alterações. As imagens 10 e 15 apresentaram ICs elevados (entre 0,5 e 0,6) para uma segunda classe, diferente da correta. A imagem 14 de fato contém ambas as classes ferrita e carbonetos, conforme figura abaixo, o que justifica a classificação do modelo, apesar da classe predominante aparentemente ser a ferrita:



Figura 31 – Presença relevante de cementita (preta) em uma matriz de ferrita (branca)

Fonte: Adaptada de Metalografia dos produtos siderúrgicos comuns (COLPAERT, 2008).

A maioria das imagens problemáticas já foram analisadas previamente, com indicações da má classificação. Sumariamente, os principais problemas são: proporção (imagens 1, 4, 5, 6), escala (imagem 11) e resolução (imagens 2, 3, 5, 6). A figura abaixo mostra o resultado de novos testes com as principais imagens alteradas:

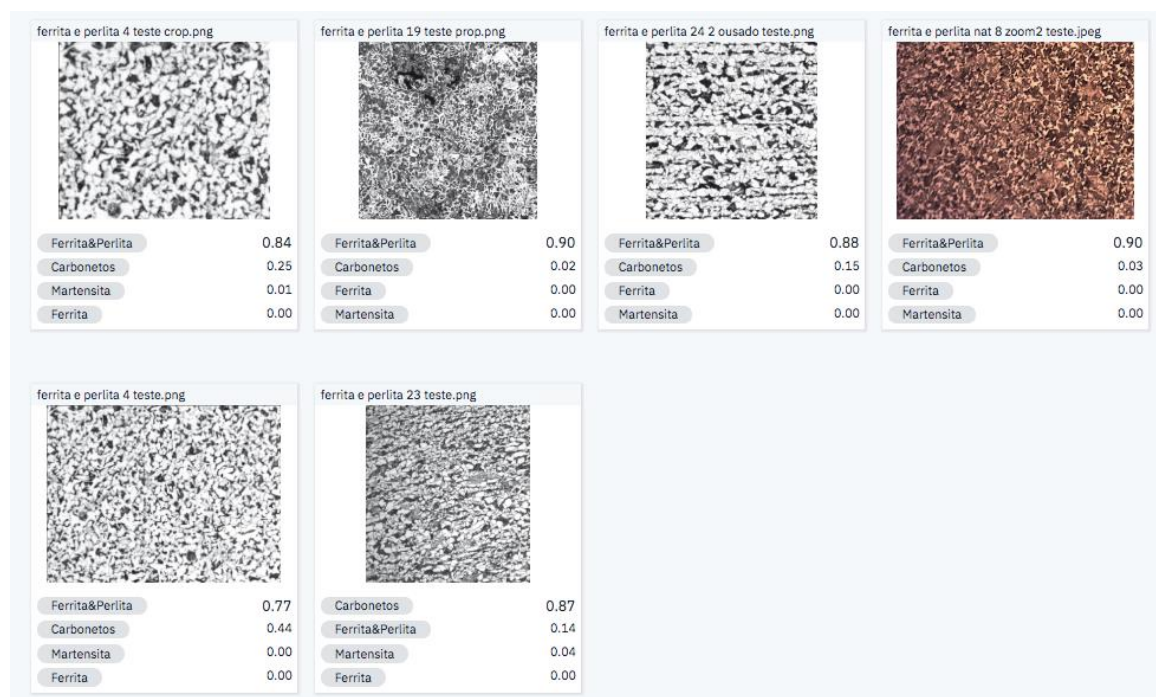


Figura 32 – Resultados obtidos na classificação de imagens alteradas da rodada de teste 3. Relacionando com a tabela, da esquerda para a direita, as imagens são alteradas a partir de: (1) 3, 4, 6, 11; (2) 3, 5.

Fonte: Elaboração própria, 2019.

Com as imagens alteradas corrigindo os principais problemas citados, apenas a foto 5 continuou com classificação errada, com classe indicada de Carbonetos, quando se trata de uma imagem de Ferrita&Perlita. As demais imagens foram classificadas corretamente a partir dos ajustes de proporção e escala.

Como a classe Martensita era a única que não tinha alcançado o valor estipulado de 80 fotos para treinamento e 20 para testes, foram buscadas novas imagens para superar o total de 100 fotos por classe. Após a inserção das novas 17 imagens na classe Martensita, não houve melhoria significativa nos índices de confiabilidade, porém a acurácia aumentou de 0,944 para 0,955, pois a única imagem classificada errada foi a mesma dos demais testes, e as novas 4 imagens de testes foram classificadas corretamente. Neste ponto, convém mudar a imagem de teste que apresenta má classificação em todos os testes, pois a mesma tem dimensões inadequadas de acordo com as boas práticas sugeridas (1164×1928 , muito próxima de 1:2). A imagem substituta será um recorte da mesma imagem, com dimensões próximas de 1:1. Convém também orientar os usuários a utilizarem fotos cuja proporção esteja mais próxima de 1:1.

Optou-se por implementar a primeira versão do modelo, pois o mesmo já apresenta bons resultados na classificação, superiores aos esperados no início do projeto. As interações com os usuários finais podem gerar insights para entender como melhorar os resultados do modelo em um segundo ciclo de inteligência artificial. Por exemplo, caso os usuários insiram fotos com grade de escala, será interessante adicionar este elemento na classe negativa do modelo, pois o mesmo não deve ser utilizado como fator classificador. Contudo, deve-se esperar pelos resultados das interações, que irão elucidar o tipo de imagem inserida pelos usuários para que ações assertivas sejam tomadas na melhoria do modelo.

4.3 SEGUNDO CICLO DE INTELIGÊNCIA ARTIFICIAL

4.3.1 Resultados obtidos da implementação da primeira versão do modelo

Com o classificador levado para a fase de inferência, foi possível receber informações de como os usuários finais interagem com o mesmo, o que é importante para que seja criado um modelo que atenda a suas necessidades. O contato com os

usuários finais também permite que o modelo seja retreinado a partir de suas interações, coletando fotos inseridas e iniciando um novo ciclo de AI.

Foram obtidas 33 respostas ao formulário Google Forms. Analisando o resultado, percebe-se que a maior parte dos usuários obteve um retorno positivo em sua classificação (63,6%), conforme gráfico abaixo:

O resultado da aplicação correspondeu ao componente microestrutural predominante em sua imagem?

33 responses




Figura 33 – Resultados da interação dos usuários finais com o modelo

Fonte: Elaboração própria, 2019.

As respostas negativas foram investigadas para entender os possíveis motivos para o erro do modelo. Foram analisadas 8 imagens. Dentre elas, apenas 2 continham martensita em placas, microconstituente para o qual o modelo havia sido treinado, sendo as duas falhas nesta classe, Martensita. As demais imagens continham microestruturas complexas ou microconstituintes ainda não incorporados no modelo, como perlita e martensita em ripas.

A interação com os usuários e colegas permitiu a coleta de novas imagens após o lançamento da página web da aplicação, a maior parte delas através do formulário Google Forms disponível na página de resultados e as demais via e-mail ou contato pessoal com colegas. Apenas duas das imagens inseridas no formulário apresentavam barra de escala, portanto, não há necessidade de incluir exemplos de barras de escala na classe negativa do modelo neste momento. As novas imagens foram inseridas nas pastas de arquivo de suas respectivas classes, para serem

utilizadas no momento oportuno de refino do modelo. Foram obtidas imagens para as classes Ferrita&Perlita, Martensita e Carbonetos, além de outras imagens representativas de perlita pura, de martensita em morfologia de ripas ou mista e imagens de uma microestrutura complexa de bainita, martensita, perlita e austenita.

4.3.2 Treinamentos da segunda versão do modelo

Da mesma forma como foram realizados os demais testes, foram anotadas as classes sugeridas para cada imagem, bem como o IC correspondente a cada uma delas. Os resultados gerais do modelo foram muito promissores, conforme tabela abaixo:

Tabela 12 – Resultados da rodada de teste entre Ferrita&Perlita, Martensita, Carbonetos, Ferrita e Martensita&Austenita

Classes	Total de Imagens de Treinamento	Total de imagens de Teste	Total de Acertos	Acurácia	Índice de Confiabilidade Médio
Ferrita&Perlita	260	51	46	0,902	0,847
Martensita	260	64	64	1,000	0,766
Carbonetos	110	27	27	1,000	0,905
Ferrita	95	24	23	0,958	0,869
TOTAL	725	166	160	0,964	-

Fonte: Elaboração própria, 2019.

Esta tabela foi realizada considerando a classificação de Martensita como correta, mesmo se a imagem fosse representativa da classe Martensita&Austenita. Contudo, se alguma das imagens representativas da Martensita fosse considerada como Martensita&Austenita, isto seria considerado um erro de classificação, porém este caso não ocorreu. De modo a comparar as duas versões do classificador, a tabela abaixo foi criada para mostrar os resultados:

Tabela 13 – Comparação dos resultados da primeira e segunda versão do modelo

Classes	Acurácia da 1ª versão	Acurácia da 2ª versão	IC Médio da 1ª versão	IC Médio da 2ª versão
Ferrita&Perlita	0,838	0,902	0,791	0,847
Martensita	0,944	1,000	0,864	0,766
Carbonetos	1,000	1,000	0,906	0,905
Ferrita	0,950	0,958	0,866	0,869
TOTAL	0,919	0,964	-	-

Fonte: Elaboração própria, 2019.

Não houve decréscimo no IC máximo obtido (0,91). Além disso, as classes Ferrita&Perlita e Ferrita apresentaram melhoria no IC médio e na acurácia. A classe Carbonetos praticamente não sofreu alterações. Possivelmente, os resultados positivos provêm da adição de um número maior de imagens, em conjunto com o refino das mesmas. Já a classe Martensita teve redução mais expressiva no IC. Isto é esperado pois a adição de novas classes pode introduzir elementos de similaridade entre as mesmas, o que dificulta a classificação, reduzindo a confiabilidade do modelo ao sugerir uma classe. Justamente, há uma semelhança perceptível entre as classes Martensita e Martensita&Austenita.

Conforme proposto para esta etapa de refino, deve-se avaliar a qualidade do modelo em classificar corretamente as imagens representativas de martensita e austenita retida como a classe Martensita&Austenita (MA), além da classe Martensita (M). A tabela a seguir sintetiza os resultados:

Tabela 14 – Resultados comparativos entre Martensita e Martensita&Austenita

Classes	Total de Imagens de Treinamento	Total de imagens de Teste	Total de Acertos	Acurácia	Índice de Confiabilidade Médio
Martensita	260	64	64	1,000	0,766
Martensita (ripas) ¹³	118	29	29	1,000	0,892
Martensita&Austenita	142	35	13	0,371	0,572

Fonte: Elaboração própria, 2019.

¹³ Não é uma classe, apenas para referência das imagens utilizadas para compor a classe Martensita, além de informar as imagens de treinamento com morfologia de ripas.

Os resultados mostram que a classificação foi dual para praticamente todas as imagens de Martensita&Austenita, porém, apenas 13 das 35 imagens de testes tiveram IC maior para a classe MA, o que resulta em uma acurácia baixa de 0,371. Contudo, dentre as 22 outras imagens classificadas como M, 12 tiveram IC para a classe MA superior a 0,5, indicando uma confiança relativamente alta para a presença dessa classe. As demais 10 imagens receberam ICs variando entre 0,25 e 0,49, valor mais baixo. Ainda, para as 13 imagens cuja classificação foi correta, o IC para a classe M foi inferior a 0,5, mas não ficou abaixo de 0,45, valor este que poderia ser definido como novo *threshold* de classificação, já que de fato há presença da classe Martensita mesmo nas imagens de teste de Martensita&Austenita. Os ICs médios obtidos foram 0,572 para MA e 0,766 para M, com máximos e mínimos em 0,76 e 0,25 para MA e 0,85 e 0,45 para M. Os resultados foram menos satisfatórios para esta classe e subclasse possivelmente pela presença de imagens de martensita com morfologia mista no *set* de treinamento da classe Martensita, dada a dificuldade de selecionar fotos onde houvesse apenas martensita em ripas.

Para as imagens de testes de martensita em ripas, a acurácia do modelo foi muito alta, com 100% de acerto para a classe Martensita, além de um IC médio de 0,892, com máximo de 0,91 e mínimo de 0,80. Nenhum resultado foi dual, ou seja, com ICs superiores a 0,5 para mais de uma classe, porém em 4 das 29 imagens de teste, foi sugerida a presença da classe Martensita&Austenita. Contudo, o IC foi baixo, variando entre 0,20 a 0,38, inferior ao *threshold* de 0,5 e também do possível novo valor de *threshold* de 0,45. A tabela abaixo retrata os problemas descritos:

Tabela 15 – Piores resultados obtidos nos testes da classe Martensita&Austenita

Nome	Classe	Modelo									
		Classes					Índice de Confiabilidade (IC)				
		1	2	3	4	5	1	2	3	4	5
A01_200x 1 a	Martensita & Austenita	M	MA	C	-	-	0,74	0,50	0,01		
A01_200x 1 b	Martensita & Austenita	M	MA	C	F	-	0,81	0,32	0,04	0,01	
A01_500x_2 2 a	Martensita & Austenita	M	MA	-	-	-	0,67	0,61			
A01_500x_2 2 b	Martensita & Austenita	M	MA	C	-	-	0,66	0,61	0,01		
A01_500x_2 2 c	Martensita & Austenita	M	MA	-	-	-	0,70	0,57			
A01_500x_3 1.jpg	Martensita & Austenita	M	MA	-	-	-	0,75	0,49			
A01_1000x 2 b	Martensita & Austenita	M	MA	-	-	-	0,64	0,63			
A02_1000x_2 1 b	Martensita & Austenita	M	MA	FP	C	F	0,61	0,60	0,06	0,03	0,01
A02_1000x_2 1 c	Martensita & Austenita	MA	M	FP	-	-	0,76	0,47	0,01		
A03_200x 1 1 a	Martensita & Austenita	M	MA	-	-	-	0,77	0,46			
A03_200x 1 1 b	Martensita & Austenita	M	MA	-	-	-	0,70	0,57			
A03_500x 3	Martensita & Austenita	M	MA	-	-	-	0,84	0,29			
borda 500x Sub 1 a	Martensita & Austenita	MA	M	C	F	-	0,75	0,46	0,04	0,01	
martensita doit 332 2	Martensita & Austenita	M	MA	-	-	-	0,67	0,60			
martensita e austenita mhb 17 c	Martensita & Austenita	M	MA	-	-	-	0,66	0,61			
marten e austenita retida 5.19 1	Martensita & Austenita	M	MA	-	-	-	0,84	0,27			
martensita mhb 39 a	Martensita & Austenita	M	MA	-	-	-	0,85	0,25			
martensita mhb 39 b	Martensita & Austenita	M	MA	-	-	-	0,80	0,39			
11-Figure2.5-1 martenplacas 1	Martensita & Austenita	M	MA	-	-	-	0,67	0,60			
MA 500x1 1.1	Martensita & Austenita	M	MA	-	-	-	0,76	0,47			
martensita placa hiveminer.jpg	Martensita & Austenita	M	MA	C	-	-	0,72	0,52	0,01		
5 500x - Bruno Marino q2	Martensita & Austenita	M	MA	-	-	-	0,77	0,46			
MA 500x1.jpg	Martensita & Austenita	MA	M	C	-	-	0,75	0,45	0,06		
martensita placas 2 GVV a1	Martensita & Austenita	M	MA	-	-	-	0,79	0,40			
im5 - 1000x - Bruno Marino q4	Martensita & Austenita	M	MA	-	-	-	0,69	0,58			

Fonte: Elaboração própria, 2019.

A tabela a seguir sintetiza os piores resultados obtidos nesta etapa para análise, excluindo as imagens da classe Martensita&Austenita, que já foram discutidas acima:

Tabela 16 – Piores resultados dos testes da segunda versão do modelo, excluindo a classe Martensita&Austenita

#	Nome	Classe	Modelo									
			Classes					Índice de Confiabilidade (IC)				
			1	2	3	4	5	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5
1	ferrita e perlita 3.53 3	Ferrita& Perlita	C	FP	M	-	-	0,86	0,22	0,01		
2	ferrita e perlita 19.png	Ferrita& Perlita	C	FP	M	-	-	0,87	0,19	0,01		
3	ferrita e perlita 23.png	Ferrita& Perlita	C	FP	-	-	-	0,90	0,02			
4	ferrita e perlita 24 2 ousado	Ferrita& Perlita	C	FP	-	-	-	0,73	0,52			
5	ferrita e perlita grossa mhb 75	Ferrita& Perlita	M	FP	C	-	-	0,60	0,50	0,27		
6	ferrita e perlita nat 8 zoom2	Ferrita& Perlita	FP	C	-	-	-	0,85	0,25			
7	ferrita doit e carbonetos 223 2	Ferrita	F	FP	C	-	-	0,66	0,61	0,01		
8	ferrita e cementita 4 3	Ferrita	C	F	FP	-	-	0,72	0,53	0,01		
9	recristalizacao ferrita 17.26 4 cut2	Ferrita	F	C	MA	M	-	0,68	0,55	0,04	0,03	
10	carboneto D2 2 1	Carbonetos	C	F	FP	M	MA	0,83	0,19	0,08	0,04	0,02
11	martensita 8	Martensita	M	MA	-	-	-	0,80	0,38			
12	martensita 9	Martensita	M	MA	-	-	-	0,86	0,20			
13	martensita GVV b2	Martensita	M	C	MA	-	-	0,86	0,22	0,01		
14	martensita ripas 2 GVV b1	Martensita	M	MA	FP	-	-	0,86	0,20	0,02		
15	martensita ripas e placas 2.ripas 2 a b	Martensita	M	MA	-	-	-	0,85	0,24			

Fonte: Elaboração própria, 2019.




Figura 34 – Compilado das imagens que apresentaram pior classificação nesta etapa de testes

Fonte: Elaboração própria, 2019.

As imagens 1 a 3 apresentaram a pior classificação, pois consideraram que a imagem retratava a classe Carbonetos, quando são representativas da classe Ferrita&Perlita. Ainda, os ICs foram bastante altos para a classe Carbonetos, todos superiores a 0,86 e bastante baixos para a classe Ferrita&Perlita, inferiores a 0,22. Já para a imagem 4, a classificação também foi errada, como nas imagens 1 a 3, porém os ICs foram mais positivos, sendo o da classe FP superior a 0,5.

A imagem 5 foi classificada como Martensita, o que pode ser explicado pela morfologia da perlita retratada, que poderia ser confundida com ripas de martensita. Contudo, o IC para esta classe não foi extremamente alto, apenas de 0,60, e o IC para FP também foi de 0,5.

A imagem 6, 10 e 13 foram corretamente classificadas, porém apresentaram IC baixo para outras classes que não estavam presentes, o que pode ser desconsiderado por não serem superiores a 0,25.

A imagem 7 foi classificada corretamente, com um IC de 0,66 para a classe correta, mas apresentou IC para a classe FP de 0,61, relativamente alto, mesmo não havendo presença de perlita na imagem, apenas alguns carbonetos. Caso semelhante ocorreu na imagem 9, com um IC de 0,68 para a classe correta e de

0,55 para Carbonetos. Nesta imagem, notam-se pontos pretos decorrentes da recristalização da ferrita, o que pode justificar a classificação do modelo.

A imagem 8 foi classificada erroneamente, conforme já havia acontecido na versão prévia do modelo. Porém, o IC da classe correta não foi baixo, sendo 0,53 para Ferrita.

Por fim, as imagens 11, 12, 14 e 15 apresentam o mesmo problema, onde a classe Martensita&Austenita foi identificada com IC baixo, porém não irrelevante, variando entre 0,20 a 0,38. Isto pode ter ocorrido pois as imagens não mostram martensita de morfologia completamente em ripas, induzindo a sugestão de presença de martensita em placas pelo modelo.

4.4 DISCUSSÕES

O Watson™ Visual Recognition apresenta limitações no âmbito do reconhecimento de imagens. Por ser de natureza classificadora, ele interpreta a imagem inserida como um todo, assumindo-a como representativa de uma das classes para as quais foi treinado. Não há detecção de pequenas particularidades presentes na imagem, destacando-as como determinada classe. Este é outro campo de visão computacional: detecção de objetos. Dessa forma, apesar dos bons resultados obtidos, esta abordagem pode não ser a mais adequada para tratar de microestruturas mais complexas, com uma presença maior de microconstituintes e em morfologias mais diversas. Assim, deve-se avaliar se a imagem do caso de uso deve ou não ser avaliada como um todo. Se os microconstituintes apresentarem particularidades bem definidas, diversas classes podem ser criadas com combinações dessas particularidades. Mas, caso a combinação entre elas seja aleatória, esta não é uma boa opção. De fato, será difícil para o modelo identificar completamente todas as microestruturas presentes em uma imagem, considerando que uma fase pode aparecer como um pequeno detalhe no quadro geral, como é o caso da microestrutura abaixo:




Figura 35 – Microestrutura composta por martensita (clara), perlita (escura e arredondada) e bainita (escura e acicular). Além disso, há presença de ferrita (também clara), conforme indicada na imagem.

Fonte: Elaboração própria, aula de metalografia, 2019.

Ainda, há certa limitação na definição das classes para microconstituintes, pois alguns possuem morfologias díspares, como é o caso da martensita (em ripas e em placas, além das estruturas mistas). Isso é reversível ao se criar classes para as diferentes morfologias. Contudo, é sabido que o modelo do Watson™ Visual Recognition, em seu treinamento, utiliza todas as classes como exemplos negativos para a classe que está sendo treinada. Deste modo, os resultados podem ser prejudicados caso sejam criadas muitas classes para as diversas morfologias de um microconstituinte, pois as mesmas podem apresentar semelhanças entre si (maior do que com as demais classes ou microconstituintes), o que diminui o índice de confiabilidade do modelo e também sua acurácia, conforme observado na segunda versão do modelo.

Vale ressaltar que a microscopia óptica não deve ser a única etapa na caracterização de um material, dado que materiais com composição distintas podem apresentar padrões microestruturais semelhantes. Mesmo quando realizada por humanos, a análise microestrutural não é definitiva e deve ser acompanhada de outros ensaios, como o de dureza, para caracterizar adequadamente um material. Dessa forma, este trabalho prevê que o usuário já possui conhecimento sobre a composição do material sendo estudado, que deve ser um aço. Caso contrário, o

resultado fornecido pelo modelo não será confiável, pois o mesmo foi treinado apenas com imagens de aço, sendo aplicável somente para este material.

Ainda que apresente certas limitações, devem-se destacar os pontos positivos, principalmente a facilidade de criar o modelo em relação aos outros classificadores desenvolvidos para o âmbito microestrutural. As vantagens mais notáveis são: a possibilidade de desenvolver o modelo mesmo com poucas imagens, quantidade comparável aos trabalhos estudados na seção 2.4; a versatilidade e flexibilidade para escolha do caso de uso a ser modelado, já que os algoritmos utilizados pelo Visual Recognition não são fixados, podendo sofrer adaptações para se adequar ao caso; a falta de necessidade de se aprofundar matematicamente nos algoritmos de *machine learning*, apesar de que o conhecimento prévio do funcionamento do modelo do Watson é desejado, para avaliar se o caso de uso pode ser atendido pelo mesmo; também, não há necessidade de conhecimentos vastos de programação, pois não é preciso criar uma interface de visualização ou de desenvolvimento do modelo, que costuma ser realizada através de bibliotecas do Python, entre outras formas, já que o próprio Watson™ Studio já configura uma interface amigável para treinamentos e testes; por fim, a possibilidade de aplicar uma abordagem holística na solução do caso de uso estudado, desde a criação do modelo até sua implantação em uma interface com os usuários finais.

Mesmo com as poucas imagens, os resultados alcançados foram positivos, com acurácia superior a 90%. É difícil comparar este valor com os estudos da área, pois não foi informado como o cálculo de acurácia foi realizado. Entretanto, a quantidade de imagens utilizadas está em linha com os trabalhos estudados (CHOWDHURRY *et al.*, 2016; DECOST; FRANCIS; HOLM, 2017), nos casos em que foi realizada a classificação de maneira semelhante à aqui descrita. Outro resultado positivo é a velocidade de resposta na classificação de uma imagem enviada, praticamente imperceptível. Ainda, não houve necessidade de larga preparação de amostras em laboratório para criar o banco de imagens, pois a internet forneceu uma quantidade aceitável e de baixo viés. Foram utilizadas imagens obtidas em aula para complementar o banco. Porém, poderiam ter sido preparadas amostras de aços cuja microestrutura fosse de interesse para o trabalho, pois aumentaria a quantidade de imagens no banco de maneira mais direcionada, ou seja, complementando determinada classe desejada. Contudo, a preparação de

amostras para montagem de banco de dados pode carregar um viés de aquisição de imagens, vinculado às condições do laboratório (equipamentos, luminosidade) e das amostras (origem, preparação) (DECOST; FRANCIS; HOLM, 2017).

Apesar da aplicação desenvolvida ser direcionada para microestrutura de aços, é possível utilizar outras micrografias, seguindo a mesma abordagem. Isto é, o Watson™ Visual Recognition pode ser customizado para o caso de uso de interesse. Vale ressaltar a importância de selecionar um caso de uso cujas imagens envolvidas apresentem certa padronização, pois sabe-se que existe uma gama de fatores que alteram a imagem obtida por um microscópio óptico, como a resolução, escala, luminosidade, ataque químico utilizado na amostra, entre outros já comentados neste trabalho. Consequentemente, o ato de padronizar facilita todas as etapas, desde a aquisição e seleção das imagens até a separação das mesmas nas classes, além de possivelmente melhorar os resultados, ainda mais se as imagens inseridas na aplicação seguirem os mesmos padrões das empregadas nos treinamentos e testes. A aplicação desenvolvida neste trabalho poderia apresentar melhores resultados para um caso de uso com imagens delimitadas, sendo utilizada, por exemplo, para encontrar imagens fora de um padrão. Porém, em um caso de uso com imagens amplas, obtidas de diversas fontes, como é o caso deste estudo, a padronização de imagens é mais restrita, portanto, os resultados podem ser mais variáveis. Por isso, uma das etapas mais longas do processo foi a coleta de imagens para montar o banco de dados/imagens. Em casos onde já exista um banco de imagens estruturado, o modelo poderá ser criado e testado com muita rapidez. Se os dados estiverem catalogados, a separação em classes também será facilitada, diminuindo ainda mais o tempo desta etapa. Na hipótese de que haja disponibilidade de imagens padronizadas, a aplicação do modelo em análises quantitativas torna-se mais viável, possibilitando treinar a aplicação para identificar parâmetros como o tamanho de grãos ou quantificar determinados microconstituintes, através de classes que representem uma faixa de composição.

A única etapa do ciclo de AI aplicado ao caso de uso estudado neste trabalho que requer a presença de um especialista seria na anotação dos dados, na fase 2 (Dados) do Ciclo de AI, onde é importante possuir conhecimento na área de micrografias para agrupar corretamente as imagens em classes. Quanto às demais fases do ciclo, a interface amigável do Watson™ Studio é capaz de dispensar a necessidade de matemáticos ou especialistas em computação, pois os algoritmos

estão embutidos no sistema e não são customizáveis. Apesar de a falta de customização dos algoritmos poder ser um ponto negativo ao se abordar a independência do tratamento dos dados, o próprio Watson foi treinado com diversos tipos de algoritmos de *deep learning*, e realiza internamente testes de adesão para determinar o melhor modelamento para o conjunto de imagens inserida, eliminando uma etapa longa do processo de desenvolvimento de algoritmos de *machine learning* por conta própria. Deve-se destacar que o processo de desenvolvimento de um classificador via métodos de *machine learning* requer o modelamento de algoritmos em três etapas (*feature extraction*, *feature selection* e classificação), tornando este estudo matemático ainda mais complexo. O Watson™ Visual Recognition não requer o modelamento destas etapas por parte da pessoa que está desenvolvendo o classificador, pois já realiza as etapas de *feature engineering* internamente, através de testes de combinações entre vários algoritmos nas diversas etapas desse processo, baseados no banco de imagens fornecido (IBM CLOUD, 2019). Porém, as combinações de táticas utilizadas nos trabalhos estudados na seção 2.4 sugerem hipóteses a serem testadas. Por exemplo, Chowdhury *et al.* (2016) e Dutta *et al.* (2019) utilizaram o algoritmo de Otsu para facilitar a etapa de extração de características (*feature extraction*). Este algoritmo determina o *threshold* (limiar) ótimo na escala de cinza para binarizar uma imagem. Neste trabalho, este algoritmo poderia ser aplicado às imagens para treinar o modelo, porém, as imagens inseridas pelos usuários também deveriam seguir este padrão. Portanto, a interface com o usuário deveria conter esta etapa de transformação antes de enviar a imagem para a análise do classificador. Como não são divulgados quais algoritmos o Watson™ Visual Recognition utiliza, nem em quais etapas, é possível que o algoritmo de Otsu ou outro similar seja aplicado internamente. Outra tática interessante é a abordagem de tarefas de classificação. A separação em tarefas de classificação parece ser um método mais adequado ao algoritmo Watson™ Visual Recognition, pois utiliza uma lógica binária, que combina com o método de classificação empregado por esta ferramenta da IBM (IBM CLOUD, 2019). No trabalho de Chowdhury *et al.* (2016), houve a separação de tarefas binárias (se a morfologia é ou não dendrítica, se o corte é ou não de uma seção transversal), o que pareceu refinar os resultados nas classificações. Um exemplo de tarefa binária seria o reconhecimento de uma fase/microconstituente ou inclusão em determinada imagem, sendo uma tarefa binária subsequente a

determinação de algum parâmetro relativo ao componente reconhecido, como determinar a morfologia de um microconstituente ou o tipo de inclusão. Ainda, uma possibilidade para melhorar os resultados de modelos de *machine learning*, especialmente os que utilizam redes neurais (algoritmo de *deep learning*), seria pré-treinar a rede com imagens de bancos de texturas, que podem ser encontradas em sites como o ImageNet, destinado a este fim. Os resultados dos estudos de Chowdhury *et al.* (2016) e DeCost, Francis e Holm (2017) indicam que a utilização de algoritmos de redes neurais pré-treinadas representam bem imagens de microestruturas, conferindo boa acurácia, boa generalização para outros casos com novos bancos, além de permitirem uma menor utilização de imagens no banco de treinamento. No caso do Watson™ Visual Recognition, da maneira como foi apresentado neste trabalho, não foi possível pré-treinar o classificador com imagens de bancos como o ImageNet, pois a interface de montagem do modelo é bem básica e focada nas classes a serem criadas a partir das imagens inseridas. Todo o modelamento matemático e algoritmos utilizados não são acessíveis, sendo o pré-treinamento uma tarefa mais complexa do que a proposta neste estudo, possivelmente envolvendo outros produtos da IBM, nos quais seria possível acessar o código e algoritmos utilizados.

Uma vantagem deste estudo em relação aos demais foi o desenvolvimento de uma interface com o usuário final. Ainda que a aplicação desenvolvida esteja em um estágio de piloto, é válido notar a facilidade de integração que a IBM proporciona em seus serviços. Neste trabalho, não foi necessária a atuação de especialistas em computação, pois a aplicação desenvolvida é bem simples e baseada em instruções disponíveis na internet, o que permite que seja implementada de maneira autônoma. Contudo, em casos de integrações com sistemas mais complexos, será necessária a participação de um desenvolvedor, com conhecimentos em integrações (API/SDKs¹⁴), *back-end*¹⁵ e possivelmente, *front-end*¹⁶. Vale ressaltar a possibilidade de integrar o Watson com sistemas de IoT, uma tendência forte na indústria, atualmente (IBM WATSON IOT, 2018). Outro ponto positivo é a acessibilidade desta

¹⁴ *Software Development Kit* (SDK) é um kit que contém todas as instruções necessárias que permitem a criação de sistemas e desenvolvimento de aplicações (MUNDO API, 2016).

¹⁵ É o desenvolvedor responsável por criar as funcionalidades que um sistema apresenta, pelo desenvolvimento do software que contém as regras de negócio, pela interação com bases de dados e pela criação de APIs e outros recursos (CARDOZO, 2017).

¹⁶ É o desenvolvedor responsável pela interface entre o sistema e o usuário, preocupando-se com a experiência do mesmo (CARDOZO, 2017).

solução, uma vez que todos os serviços foram utilizados na versão *Lite* (gratuita), cujas limitações de uso são largas, proporcionando 1000 chamadas de API por mês para o uso do Watson™ Visual Recognition (ou seja, um total de 1000 imagens treinadas/testadas), além de todos os serviços utilizados poderem ser comportados em uma única conta. Um ponto de atenção é a natureza na nuvem (*Cloud*) dos serviços, o que pode causar instabilidade em momentos de atualização ou em redes de menor banda.

5 CONCLUSÃO

O presente estudo foi uma investigação introdutória e teve como objetivo testar a possibilidade de desenvolver um modelo de reconhecimento visual a partir da inteligência artificial da IBM, o Watson™, que seja capaz de classificar microestruturas qualitativamente, além de desenvolver uma aplicação simples e acessível para promover a interação com os usuários finais. Para tanto, foi selecionado o caso de uso de ferramenta de suporte acadêmico para estudantes universitários, focado em microestruturas de aço, um metal muito estudado em cursos como engenharia metalúrgica e de materiais. As imagens para criação do modelo foram obtidas de diversas fontes, principalmente da internet e de livros digitalizados. O modelo foi criado com dois serviços da IBM, o Watson™ Visual Recognition (que possui os algoritmos e a inteligência artificial) e o Watson™ Studio (interface para desenvolver o modelo). O classificador foi integrado com uma página na internet, pela qual alunos e pesquisadores da Escola Politécnica da USP puderam interagir. Os resultados desta interação foram utilizados para refino do modelo.

Dada a alta demanda por automação de processos, principalmente naqueles que possuem etapas manuais, o presente estudo revela-se promissor para desenvolvimento de *softwares* integrados a bancos de dados, possibilitando uma análise qualitativa de imagens microestruturais. A adaptabilidade dos algoritmos a diversos tipos de imagens permite que muitos casos de uso industriais sejam atendidos, principalmente se tratando de classificações binárias, como seria o caso de presença de inclusões.

Quanto ao desenvolvimento de um classificador customizado utilizando o Visual Recognition, destaca-se a importância de padronizar as imagens a serem utilizadas, estruturando mais facilmente o banco de dados e promovendo melhores resultados para o caso delimitado. A dificuldade de definir parâmetros para delimitar o caso de uso estudado neste trabalho (aços) delongou a concepção do modelo. Apesar disso, o classificador desenvolvido apresentou bons resultados de acurácia e confiabilidade média das classes, com 91,9% e 0,791 (limite inferior – classe Ferrita&Perlita) / 0,906 (limite superior – classe Carbonetos), respectivamente, na primeira versão do modelo, além da classificação ocorrer em um intervalo de tempo

muito baixo, praticamente imperceptível para humanos. Após a interação com os usuários finais, foram acrescentadas novas imagens de martensita em morfologia de ripas a classe Martensita do modelo, além de criar uma nova classe apenas para a martensita em morfologia de placas, que possui austenita retida (Martensita&Austenita). Com os ajustes, o modelo geral passou a ter acurácia de 96,4% e confiabilidade média das classes de 0,766 (limite inferior – classe Martensita) / 0,905 (limite superior – classe Carbonetos). Mesmo com os bons resultados, deve-se notar que a classificação promovida trata a imagem como um todo, sem detectar pequenos detalhes da mesma, o que limita sua aplicabilidade em microestruturas mais complexas. Nestes casos, as condições de análise devem ser bem definidas, além de entender se as imagens do caso de uso podem ser avaliadas como um todo. Caso existam particularidades bem definidas, diversas classes podem ser criadas com combinações dessas particularidades. Mas, caso a combinação entre elas seja aleatória, esta pode não ser a melhor opção. Contudo, para tarefas binárias ou microestruturas mais simples ou bem definidas, o modelo oferece uma solução oportuna.

Apesar das limitações, a acurácia obtida foi maior do que a esperada nos objetivos (60%), além de ser bastante superior a classificação aleatória. Ainda, a integração com a página web demonstra a facilidade de criar uma aplicação completa, mesmo sem a participação de desenvolvedores especialistas, como foi o caso deste trabalho. Dessa forma, a tese inicial foi comprovada.

Por fim, vale ressaltar que os serviços aqui estudados demonstram potencial para aplicações mais ambiciosas, com possibilidade de serem empregados em diversas áreas da Engenharia Metalúrgica e de Materiais, nos variados assuntos relacionados a imagens, conforme a seção de trabalhos futuros a seguir irá esclarecer.

6 SUGESTÕES PARA TRABALHOS FUTUROS

O modelo desenvolvido foi um passo inicial que provou que a utilização dos algoritmos de *deep learning* do serviço Watson™ Visual Recognition da IBM são capazes de interpretar imagens de microestruturas. Dada a importância de se conhecer o aspecto microestrutural de um material, a comprovação da tese sugere diversos novos caminhos a serem explorados. Como o serviço pode ser montado por pessoas sem conhecimento técnico na área de programação, pode ser uma solução para a questão do conhecimento matemático e de ciência de dados requerido para desenvolver algoritmos, caso as condições e materiais de análise sejam bem padronizados. Além disso, o retorno da classificação ocorre em um intervalo de tempo muito baixo, praticamente imperceptível a humanos. Esta vantagem torna o serviço aplicável a outras análises, principalmente as que constam com atividades manuais, como a quantificação de fases e/ou microconstituintes através de estereologia, que pode prescindir de uma análise humana quanto aos níveis de contraste aplicados e diversos cálculos de média para chegar a uma composição esperada. Assim, a velocidade de resposta, aliada aos bons resultados e à facilidade de integração com outros sistemas viabiliza a aplicação no ramo industrial, potencializando a automação de processos.

Uma hipótese é a de que o Watson Visual Recognition pode ser utilizado tanto em aplicações qualitativas, como a descrita neste trabalho, quanto em aplicações quantitativas.

Uma importante aplicação quantitativa é a determinação de tamanho de grão. Também, um modelo empregando o Watson™ Visual Recognition poderia ser treinado para quantificar determinados microconstituintes, através de classes representantes de uma faixa de composição, incluindo a conversão para o valor correspondente à quantidade de carbono no aço a partir de um aplicativo de inteligência artificial. Um exemplo onde isto seria possível são aços hipoeutetóides ou eutetóides, cuja microestrutura é majoritariamente de ferrita e perlita, onde a fração volumétrica de perlita permite calcular o teor de carbono do aço. Outro ramo onde este produto da IBM pode ser aplicado é na análise e controle de qualidade, já que as amostras examinadas costumam ter sua preparação padronizada e seguir um conjunto de análises também bem definidas. Neste caso, poderiam ser

desenvolvidos modelos capazes de identificar inconformidades ou inclusões, ou outras condições que não atendam aos padrões de qualidade. Além disso, os modelos não se restringem a materiais metálicos e a aplicação se estende para toda a área de metalografia.

Uma forma de complementar este trabalho seria o desenvolvimento de um *chatbot* simples, que auxiliaria o usuário na utilização do modelo. As respostas do *chatbot* poderiam ser condicionadas de acordo com a classificação realizada pelo modelo, sugerindo novas análises a serem realizadas pelo usuário, como ensaios de dureza, ou correlacionando a microestrutura predominante com possíveis propriedades do material. Outra opção para a aplicação desenvolvida é torná-la mais interativa através de um pequeno pré-questionário sobre a imagem a ser inserida no modelo, onde seriam informadas a escala e ataque utilizados. Assim, a aplicação poderia avaliar apenas as classes referentes aos padrões informados. Para isso, mais imagens devem ser coletadas e novas classes precisarão ser criadas.

REFERÊNCIAS¹⁷

ASM International. **Metallography and microstructures**. Materials Park, OH: ASM International, 2004. ASM Metals Handbook, v. 9. ISBN: 0-87170-706-3

ASSESSORIA DE IMPRENSA IBM BRASIL. **Volkswagen Virtus será o primeiro carro no Brasil a usar inteligência artificial para ajudar motoristas**. IBM Sala de Imprensa. 2017. Disponível em <<http://www-03.ibm.com/press/br/pt/pressrelease/53402.wss>>. Acesso em: 25 de Janeiro de 2019.

BHADESHIA, H. K. D. H. **Metallography of Steels**: University Interpretation of the Microstructure of Steels. University of Cambridge, 2008. Disponível em: <https://www.phase-trans.msm.cam.ac.uk/2008/Steel_Microstructure/SM.html>. Acesso em: 11 de Fevereiro de 2019.

BHADESHIA, H. K. D. H. **High Performance Bainitic Steels**. University of Cambridge, 2005. Disponível em: <<http://www.phase-trans.msm.cam.ac.uk/2005/performance/paper.html>>. Acesso em: 11 de Fevereiro de 2019.

BISHOP, C. M. **Pattern recognition and machine learning**. 1a. Ed. Springer, 2006. ISBN-13: 978-0387-31073-2.

BROWNLEE, J. **A tour of machine learning algorithms**. 2013. Disponível em: <<https://machinelearningmastery.com/a-tour-of-machine-learning-algorithms/>>. Acesso em: 24 de Janeiro de 2019.

BULGAREVICH, D. S. et al. **Pattern recognition with machine learning on optical microscopy images of typical metallurgical microstructures**. *Nature: Scientific Reports*, v. 8, n. 1, p. 1-8, 2018.

CAMPBELL-KELLY, M. A. **A origem da computação**. 2009. Disponível em: <https://www2.uol.com.br/sciam/reportagens/a_origem_da_computacao.html>. Acesso em: 23 de Janeiro de 2019.

CARAYANNIS, G. **Artificial intelligence and expert systems in the steel industry**. *JOM - The Journal of The Minerals, Metals & Materials Society (TMS)*, v. 45, n. 10, p. 43-51, Outubro, 1993. ISSN: 1543-1851.

DE CARVALHO, P. S. L. et al. **Minério de ferro**. *Insumos básicos*, BNDES Setorial, v. 39, p. 197-234, 2014.

CARDOZO, F. **Front-End ou Back-End? Entenda as diferenças e descubra o seu perfil**. 2017. Disponível em: <<https://blog.mxcursos.com/front-end-ou-back-end-entenda-as-diferencas-e-descubra-o-seu-perfil/>>. Acesso em: 15 de Junho de 2019.

¹⁷ De acordo com a Associação Brasileira de Normas Técnicas (ABNT NBR 6023)

DE CASTRO, A. A. M.; DO PRADO, P. P. L. **Algoritmos para Reconhecimento de Padrões**. *Rev. Ciênc. Exatas*, Taubaté, n. 5-8, p. 129-145, 1999-2002.

Centro Tecnológico de Minas Gerais (CETEC). **Ciência dos materiais**: Capítulo 9 - Estruturas Longe das Condições de Equilíbrio - Tópico 9.11. O Sistema Fe-C (VI): Bainita e Martensita. 2007. Disponível em: <[http://www.cienciadosmateriais.org/index.php?acao=exibir&cap=13&top=281#_ftn\(3\)](http://www.cienciadosmateriais.org/index.php?acao=exibir&cap=13&top=281#_ftn(3))>. Acesso em: 21 de Janeiro de 2019.

CHIAVERINI, V. **Tecnologia Mecânica**: Processos de fabricação e tratamento. 2a Ed. São Paulo: McGraw-Hill, 1986. V. III.

CHOWDHURRY, A.; KAUTZ, E.; YENER, B.; LEWIS, D. **Image driven machine learning methods for microstructure recognition**. *Computational Materials Science*, New York, Junho, 2016.

CODE TUBE. **Image Upload with Imgur Api**. Youtube. 2017. 4 min 14 seg, son., color. Disponível em: <<https://www.youtube.com/watch?v=qmNbZmBOaGM>>. Acesso em: Maio de 2019.

COELHO, D. M. S. **Efeito da Temperatura de Austenitização no Processo de Têmpera e Partição**. 2008. 100f. Dissertação de Mestrado – PUC-Rio, Rio de Janeiro, 2008.

COLPAERT, H. **Metalografia dos produtos siderúrgicos comuns**. 4a. Ed. São Paulo: Blucher, 2008.

DECOST, B. L.; FRANCIS, T.; HOLM, E. A. **Exploring the microstructure manifold**: image texture representations applied to ultrahigh carbon steel microstructures. *Elsevier*, Pittsburg, Maio, 2017.

DEGRIGNY, C. **Microstructure and corrosion of steels database**. Haute école Arc, 2016. Disponível em: <<https://micorr.org>>. Acesso em: Abril de 2019. Biblioteca online de microestruturas.

DIETRICH, A. **O ciclo de AI**. 2018. 30 min 20 seg, son., color. Disponível em: <<https://www.youtube.com/watch?v=eNWkJbzpyuE&list=PLYklth3EpPeFIGfNAyTO0GJj4ZwoTDq0i>>. Acesso em: 8 de Dezembro de 2018. Web-série de 5 vídeos.

DURÁN, R. A. **Proyecto de Innovación Atlas Metalográfico**. Universidad Complutense Madrid. 2016. Disponível em: <<https://www.ucm.es/atlasmetalografico/aceros>>. Acesso em: Abril-Maio de 2019. Biblioteca de imagens digitais de microestruturas.

DUTTA, T.; DAS, D.; BANERJEE, S.; SAHA, S. K.; DATTA, S. **An automated morphological classification of ferrite-martensite dual-phase microstructures**. *Measurement*, v. 137, p. 595-603, 2019.

ERICSSON, T. Principles of Heat Treating of Steels. In: **Metals Handbook**: Heat Treating. 3. Ed. Ohio: ASM International, 1995. v. 4, p. 14-18. ISBN: 0-87170-379-3.

FONTOURA, P. R. **Alan Turing, o pai da computação**. Invivo – História. 2013. Disponível em: <<http://www.invivo.fiocruz.br/cgi/cgilua.exe/sys/start.htm?infoid=1370&sid=7>>. Acesso em: 14 de Junho de 2019.

HONEYCOMBE, R. W. K. **Aços: Microestrutura e propriedades**. Ed. Portuguesa. Lisboa: Fundação Calouste Gulbekian, 1985.

IBM. **Watson**: About. Disponível em: <<https://www.ibm.com/watson/about/index.html>>. Acesso em: 7 de Janeiro de 2019.

IBM BRASIL. **Jornada Digital Gerdau**. Youtube. 2018. 2 min, 3 seg, son., color. Disponível em: <<https://www.youtube.com/watch?v=NWu0jHP3nqo&feature=youtu.be>>. Acesso em: 7 de Janeiro de 2019.

IBM CLOUD. **Diretrizes para treinar classificadores**. IBM Cloud Docs, 2019. Disponível em: <<https://cloud.ibm.com/docs/services/visual-recognition?topic=visual-recognition-customizing&locale=pt-br>>. Acesso em: Março – Maio de 2019.

IBM WATSON IOT. **Explore the Internet of Things (IoT)**. 2018. Disponível em: <<https://www.ibm.com/internet-of-things>>. Acesso em: 15 de Junho de 2019.

JIMENÉZ, V. **A nova era da computação e seus primeiros movimentos no Brasil**. 2015. Disponível em: <https://brasil.elpais.com/brasil/2015/07/02/tecnologia/1435845247_202110.html>. Acesso em: 23 de Janeiro de 2019.

KITAHARAA, H.; UEJI, R.; TSUJI, N.; MINAMINO, Y. **Crystallographic features of lath martensite in low-carbon steel**. *Acta Materialia*, v. 54, n. 5, p. 1279-1288, 2006.

KOMENDA, J. **Automatic recognition of complex microstructures using the Image Classifier**. *Materials Characterization*, Stockholm, v. 46, p. 87-92, 2001.

KRAUSS, G. **Steels: Processing, structure and performance**. 2. Ed. Materials Park, Ohio: ASM International, 2015.

LEE, I. **Big data: Dimensions, evolution, impacts, and challenges**. *Business Horizons*, v. 60, n. 3, p. 293-303, 2017.

LI, S. **Influence of Tempering on the Microstructure & Properties of Martensite and Bainite developed in a Low-C High-Si Steel**. 2017. 52f. Dissertação de Mestrado – TU Delft, Delft, 2017.

LIDE, D. R. **CRC Handbook of Chemistry and Physics**. 85. Ed. Boca Raton: CRC Press, 2005.

LOBO, L. C. **Inteligência artificial e medicina**. *Revista Brasileira de Educação Médica*, Rio de Janeiro, v. 41, n. 2, p. 185-193, 2017.

MANEY, K.; HAMM, S.; O'BRIEN, J. M. **Tornando o mundo melhor**: Ideias que moldaram um século e uma empresa. Upper Saddle River: Pearson, 2011.

MAZON, S. **Aulão Watson Visual Recognition**. 2018. 13 min 55 seg, son., color Disponível em: <<https://www.youtube.com/watch?v=0GpF39U9iaQ>>. Acesso em: Maio de 2019. Vídeo aula que ensina como criar um modelo no Visual Recognition e como implementar a página via Node-RED.

MAZON, S. **Watson Visual Recognition com Node-RED**. GitHub - smazon/visual-recognition, 5 de Dezembro de 2018. Disponível em: <<https://github.com/smazon/visual-recognition>>. Acesso em: Maio de 2019. Repositório com código para implementar a página web.

MUNDO API. **Você sabe as diferenças entre API e SDK?**. 2016. Disponível em: <<https://mundoapi.com.br/materias/voce-sabe-as-diferencas-entre-api-e-sdk/>>. Acesso em: 15 de Junho de 2019.

PAN, Y. **Heading towards Artificial Intelligence 2.0**. *Engineering*, Beijing, v. 2, n. 4, p. 409-413, 2016.

RICHARD, D. O.; HART, P. E.; STORK, D. G. **Pattern classification**. 2. Ed. New York: John Wiley & Sons, 2012.

RODRIGUES, F. S. A 3ª Era da Computação. **Estadão**, São Paulo, 19 de Outubro de 2014. Disponível em <<https://economia.estadao.com.br/noticias/geral,a-3-era-da-computacao-imp-,1579170>>. Acesso em: 17 de Janeiro de 2019.

RODRÍGUEZ, O. F. **Microconstituyentes de los aceros**. 2011. Disponível em: <<https://matensayos.webcindario.com/metalogracero/microconstituyente/microconstituyentes.htm>> Acesso em: Março-Maio de 2019. Biblioteca de imagens digitais de microestruturas.

ROLLO, J. M. D. A. **Diagrama ferro carbono**. 2015. Disponível em: <https://edisciplinas.usp.br/pluginfile.php/4449566/mod_resource/content/0/Aula04%20-%20Diagrama%20de%20Fases%20Ferro%20Carbono.pdf>. Acesso em: 21 de Janeiro de 2019. Notas de aula – Aula 05 – Diagrama de fases do ferro carbono.

RUSSELL, S. J.; NORVIG, P. **Artificial intelligence: a modern approach**. Englewood Cliffs: Prentice Hall, 1995. ISBN: 0-13-103805-2.

SALESFORCE BRASIL. **Machine Learning e Deep Learning**: aprenda as diferenças. Blog da Salesforce, 30 de Abril de 2018. Disponível em: <<https://www.salesforce.com/br/blog/2018/4/Machine-Learning-e-Deep-Learning-aprenda-as-diferencas>>. Acesso em: 19 de Janeiro de 2019.

SCHEER, L. **O que é aço?** 2. Ed. São Paulo: E.P.U. Editora pedagógica e Universitária Ltda, 1987.

SILVA, A. L. C.; MEI, P. R. **Aços e ligas especiais**. 2. Ed. Editora Edgar Blucher, 2006.

SOMASHEKHAR, S. P. et al. **Watson for Oncology and breast cancer treatment recommendations**: agreement with an expert multidisciplinary tumor board. *Annals of Oncology*, v. 29, n. 2, p. 418-423, 2018.

TSCHIPTSCHIN, A. P.; GOLDENSTEIN, H.; SINATORA, A. **Metalografia dos aços**. ASM, 1988. Disponível em: <http://pmt.usp.br/pmt3402/material/metalografia_dos_acos.pdf>. Acesso em: Janeiro, 2019.

UNIVERSITY OF CAMBRIDGE. **Micrograph Library**. Dissemination of IT for the Promotion of Materials Science (DoITPoMS). 2018. Disponível em: <<https://www.doitpoms.ac.uk/miclib/index.php>>. Acesso em: Março-Maio de 2019. Biblioteca de imagens digitais de microestruturas.

VAC AERO International Inc. **Vacuum Furnace Engineering, Manufacturers of Quality Vacuum Furnaces**. 2016. Disponível em: <<https://vacaero.com/>>. Acesso em: Março-Maio de 2019. Acervo de artigos digitais com diversas imagens de microestruturas.

VANDER VOORT, G. F.; MANILOVA, E. P. **Hints for imaging phases in steels**. *Advanced Materials & Processes: Microscopy/Metallography*, ASM International, v. 163, n. 2, 2005.

VANDER VOORT, G. F. **Metallography General**. 1967 – 2009. Disponível em: <<http://www.georgevandervoort.com/metallography.html>>. Acesso em: Abril-Maio de 2019. Acervo de artigos e materiais digitais com diversas imagens de microestruturas.

VANDER VOORT, G. F. **Microstructure of Ferrous Alloys**. VAC Aero International inc. 2011. Disponível em: <<https://vacaero.com/information-resources/metallography-with-george-vander-voort/894-microstructure-of-ferrous-alloys.html>>. Acesso em 18 de Maio de 2019.

VANDER VOORT, G. F. **Microstructure of Ferrous Alloys**. Buehler: *Tech Notes*, v. 3, n. 7, 2015.

VESTUR, C. **Building a performing Machine Learning model from A to Z**. SlideShare. Disponível em: <<https://www.slideshare.net/CharlesVestur/building-a-performing-machine-learning-model-from-a-to-z>>. Acesso em: 24 de Janeiro de 2019.

WANG, P. **What do you mean by "AI"?**. *Artificial General Intelligence 2008: Proceedings of the First AGI Conference*, Memphis: IOS Press, p. 362-373, 2008.

WINTER, M. **WebElements Periodic Table**: Iron: the essencial. 1993. Disponível em: <<https://www.webelements.com/iron/>>. Acesso em: 24 de Janeiro de 2019.

WOJNAR, L.; KURZYDŁOWSKI, K.J.; SZALA, J. **Quantitative image analysis**, *Metallography and Microstructures*, Materials Park, OH: ASM International, ASM Metals Handbook, v. 9, p. 403–427, 2004.

YEDDU, H. K. **Martensitic transformations in steels – A 3D Phase-field study**. 2012. 68 p. Tese (Doutorado) – KTH Industrial Engineering and Management, KTH Royal Institute of Technology, Stockholm.

YUN, Z. Y. **Imgur-Upload**. GitHub, 2017. Disponível em: <<https://github.com/carry0987/Imgur-Upload>>. Acesso em: Maio de 2019.